



Sveučilište u Zagrebu

FAKULTET PROMETNIH ZNANOSTI

KREŠIMIR VIDOVIĆ

**MODEL PROCJENE URBANE MOBILNOSTI
ZASNOVAN NA ZAPISIMA O AKTIVNOSTIMA
KORISNIKA U JAVNIM POKRETNIM
KOMUNIKACIJSKIM MREŽAMA**

DOKTORSKI RAD

Zagreb, 2018.



Sveučilište u Zagrebu

FAKULTET PROMETNIH ZNANOSTI

KREŠIMIR VIDOVIĆ

**MODEL PROCJENE URBANE MOBILNOSTI
ZASNOVAN NA ZAPISIMA O AKTIVNOSTIMA
KORISNIKA U JAVNIM POKRETNIM
KOMUNIKACIJSKIM MREŽAMA**

DOKTORSKI RAD

Mentor:
Prof. dr. sc. Sadko Mandžuka

Zagreb, 2018.



University of Zagreb

FACULTY OF TRAFFIC AND TRANSPORT SCIENCES

KREŠIMIR VIDOVIĆ

**MODEL FOR ESTIMATING URBAN MOBILITY
BASED ON THE RECORDS OF USER ACTIVITIES
IN PUBLIC MOBILE NETWORKS**

DOCTORAL THESIS

Supervisor:
Prof. Sadko Mandžuka, Ph. D.

Zagreb, 2018.

PODATCI I INFORMACIJE O DOKTORANDU

1. Ime i prezime: Krešimir Vidović
2. Datum i mjesto rođenja: 07. listopada 1980. godine, Pakrac
3. Naziv završenog fakulteta i godina diplomiranja: Fakultet prometnih znanosti Sveučilišta u Zagrebu, 2006. godina

INFORMACIJE O DOKTORSKOM RADU

1. Naziv doktorskog studija: Tehnološki sustavi u prometu i transportu
2. Naslov doktorskog rada: Model procjene urbane mobilnosti zasnovan na zapisima o aktivnostima korisnika u javnim pokretnim komunikacijskim mrežama
3. Fakultet na kojem je doktorski rad obranjen: Fakultet prometnih znanosti Sveučilišta u Zagrebu

POVJERENSTVA, OCJENA I OBRANA DOKTORSKOG RADA

1. Datum prijave doktorskog rada: 10. studenog 2016. godine
2. Mentor: prof. dr. sc. Sadko Mandžuka
3. Povjerenstvo za obranu i ocjenu doktorskog rada:
 1. izv. prof. dr. sc. Davor Brčić
 2. prof. dr. sc. Sadko Mandžuka
 3. prof. dr. sc. Dragan Peraković
 4. doc. dr. sc. Mario Muštra
 5. prof. dr. sc. Renato Filjar (vanjski član)
4. Lektorica: Martina Polenus, magistra kroatologije
5. Datum obrane doktorskog rada: 13. ožujka 2018. godine

INFORMACIJE O MENTORU: prof. dr. Sadko Mandžuka

ŽIVOTOPIS:

Sadko Mandžuka je rođen 1956. godine u Foči, Republika Bosna i Hercegovina. Gimnaziju u Bugojnu završio je 1975. godine, a Elektrotehnički fakultet Sveučilišta u Zagrebu, smjer automatika, 1980. godine. Magistrirao je 1992. godine, a doktorsku disertaciju obranio je u 2003. godine, sve na Fakultetu elektrotehnike i računarstva u Zagrebu.

Po završetku studija 1980. godine zapošljava se u UNIS – Bugojno na poslovima razvoja digitalnih sustava upravljanja, a potom 1982. godine u Brodarskom institutu u Zagrebu. Od samog početka u Brodarskom institutu radi na zadacima istraživanja i razvoja raznih sustava upravljanja plovnim objektima. Radio je kao istraživač, samostalni istraživač, voditelj odjela Razvoj sustava upravljanja te direktora Sektora za upravljanje sustavima i procesima. Bio je višegodišnji suradnik na Fakultetu elektrotehnike i računarstva, Zavod za automatiku i računalno inženjerstvo. Danas je stalno zaposlen kao redoviti profesor na Fakultetu prometnih znanosti, Zavod za inteligentne transportne sustave, gdje obnaša dužnost predstojnika Zavoda. Predaje na prediplomskom i diplomskom studiju na grupi predmeta Inteligentni transportni sustavi i Operacijska istraživanja. Na doktorskom studiju učestvuje u nastavi na više kolegija. Jedan je od utemeljitelja Sveučilišnog poslijediplomskog specijalističkog studija Upravljanje krizama gdje je nositelj kolegija Tehnički sustavi potpore upravljanja krizama.

Do sada je objavio preko 100 znanstvenih radova, više stručnih radova i nekoliko preglednih članaka. Član suradnik je Akademije tehničkih znanosti Hrvatske, član je Znanstvenog vijeća za promet Hrvatske akademije znanosti i umjetnosti, član Technical Committee on Transportation and Vehicles systems (International Federation of Automatic Control - IFAC), utemeljitelj Hrvatskog društva za robotiku, obnaša dužnost predsjednika znanstveno-stručne udruge ITS Hrvatska.

Urednik je i član uredničkog odbora više europskih i hrvatskih znanstvenih časopisa. Bio je član više međunarodnih programskih odbora za kongrese i konferencije u zemlji i inozemstvu. Bio je voditelj i sudjelovao je u više europskih i hrvatskih znanstveno-istraživačkih projekata te je recenzent više znanstvenih i istraživačko-razvojnih projekata u zemljama Europske unije.

Za dosadašnji rad nagrađivan je Medaljom rada (1987), Zahvalnicom Glavnog stožera OS RH (1996) te je dobitnik godišnje državne nagrade (1997) Ministarstva znanosti i

tehnologije i Ministarstva obrane za osobit doprinos na području tehničkih znanosti, za znanstveni doprinos u okviru rješenja sustava prostornog upravljanja podmornicom.

POPIS OBJAVLJENIH RADOVA MENTORA (izvod)

1. Huzjan, Boris; Mandžuka, Sadko; Kos, Goran, Real-time traffic safety management model on motorways, Tehnički vjesnik, 24 (2017) , 5; 1457-1469, ISSN 1330-3651
2. Vidović, Krešimir; Mandžuka, Sadko; Brčić, Davor, Estimation of urban mobility using public mobile network // Proceedings of 59th International Symposium ELMAR, Zadar, 2017. 21-24
3. Pilko, Hrvoje; Mandžuka, Sadko; Barić, Danijela, Urban single-lane roundabouts: A new analytical approach using multi-criteria and simultaneous multi-objective optimization of geometry design, efficiency and safety, Transportation Research Part C: Emerging Technologies, 2017, 80: 257-271., ISSN: 0968-090X
4. Greguric, Martin; Ivanjko, Edouard; Mandzuka, Sadko, The use of cooperative approach in Ramp metering, PROMET - Traffic&Transportation. Volume: 28 Issue: 1 Pages: 11-22, 2016, ISSN: 0353-5320
5. Mandžuka, Sadko; Gregurić, Martin; Zdenko, Kljaić, Kooperativno okruženje za infrastrukturu e- mobilnosti, Proceedings of papers 24nd Telecommunications Forum (TELFOR), Beograd, 2016.
6. Ivanjko, Edouard; Koltovska Nečoska, Daniela; Gregurić, Martin; Vujić, Miroslav; Jurković, Goran; Mandžuka, Sadko., Ramp metering control based on the Q-learning algorithm, CYBERNETICS AND INFORMATION TECHNOLOGIES, 15 (2015), 5; 88-97 ISSN: 1311-9702
7. Mandžuka, Sadko; Huzjan, Boris; Kos, Goran., Cooperative Highway Traffic Safety Management Systems // RECENT ADVANCES in SYSTEMS / Prof. Valeri Mladenov, Technical University of Sofia, Bulgaria (ur.), Zakynthos Island, Greece : Recent Advances in Electrical Engineering Series, 2015. 661-666
8. Vujić, Miroslav; Mandžuka, Sadko; Gregurić, Martin., Pilot Implementation of Public Transport Priority in the City of Zagreb, PROMET - Traffic&Transportation. 27 (2015), 3; 257-265, ISSN: 0353-5320
9. Mandžuka, Sadko; Žura, Marijan; Horvat, Božica; Bicanic, Davor; Mitsakis, Evangelos. Directives of the European Union on Intelligent Transport Systems and their impact on the Republic of Croatia., Promet - Traffic & Transportation. 25 (2013), 3; 273-283 ISSN: 0353-5320
10. Škorput, Pero; Mandžuka, Sadko; Jelušić, Niko. Real-time detection of road traffic incidents, Promet. 22, 4; 273-283, 2010., ISSN: 0353-5320
11. Šimunović, Ljupko; Bošnjak, Ivan; Mandžuka, Sadko., Intelligent Transport Systems and pedestrian traffic, Promet. 21, 2; 141-152, 2009., ISSN: 0353-5320

Doktorski rad posvećujem supruzi Dragani te kćerima Magdalen i Katarini, čije mi je nesebično i neograničeno razumijevanje te beskrajna podrška pružilo snagu kako bih ustrajao u svom radu.

ZAHVALA

Ovim putem htio bih zahvaliti svom mentoru, profesoru dr. sc. Sadku Mandžuki, koji me na pravi način uputio i vodio kroz cijeli postupak istraživanja i koji je svojim znanjem, iskustvom, idejama i savjetima utjecao na kvalitetu doktorske disertacije. Također bih se htio zahvaliti Povjerenstvu za ocjenu i obranu, predsjedniku prof. dr. sc. Davoru Brčiću, članovima prof. dr. sc. Draganu Perakoviću i doc. dr. sc. Mariu Muštri na konstruktivnim savjetima i kritikama te pruženoj pomoći tijekom istraživanja i izrade disertacije, vanjskom članu povjerenstva, prof. dr. sc. Renatu Filjaru, na velikom zalaganju i bezbrojnim satima konzultacija, te mentoru kroz studij, prof. dr.sc. Zvonku Kavranu.

Veliko hvala mojoj obitelji, supruzi Dragani, kćerima Magdaleni i Katarini, roditeljima Tomislavi i Krešimiru, sestri Augustini s obitelji te svim ostalim njenim članovima, kao i prijateljima na velikoj podršci.

Hvala i članovima svih povjerenstava u postupku stjecanja doktorata znanosti, djelatnicama referade PDS-a, kolegama s Fakulteta prometnih znanosti Sveučilišta u Zagrebu, kolegama s kojima sam radio na Institutu prometa i veza te kolegama iz kompanije Ericsson Nikola Tesla na razumijevanju, pruženim savjetima i stručnoj pomoći.

Na samom kraju, posebno hvala i prof. dr. sc Ivanu Dadiću, na čiju sam inicijativu i savjet upisao poslijediplomski doktorski studij i koji je bio jedan od ključnih motivatora za njegov završetak.

SAŽETAK

Urbana mobilnost stanovnika uobičajeno se procjenjuje postupcima usredotočenim na specifične domene (promet, logistika, ekologija, društvo i dr.), uz korištenje domenski ograničenih skupova podataka, pokazatelja i indeksa vezanih za ciljane podskupove ukupne urbane populacije (korisnici javnog prijevoza, biciklisti, vozači i dr.). U radu je predložen novi pristup procjene urbane mobilnosti stanovnika temeljen na podacima o telekomunikacijskoj aktivnosti (glasovni poziv, tekstualna poruka, pristup internetu) korisnika u javnim pokretnim telekomunikacijskim mrežama. Koristi se pristup istraživanja urbane mobilnosti stanovnika unutar domene inteligentnih transportnih sustava, kao informacijsko-komunikacijske nadgradnje klasičnog sustava prometa i transporta. Pokazatelji urbane mobilnosti u radu se izvode iz podataka o telekomunikacijskim aktivnostima i ujedanjuju se u indeks urbane mobilnosti stanovnika korištenjem metodologije višeslojnog prilagodljivog sustava neizrazitog zaključivanja zasnovanog na neuronskoj mreži. Uspostavljen je kompleksan postupak procjene urbane mobilnosti korištenjem modela indeksa urbane mobilnosti, koji je definiran postupkom strojnog učenja ANFIS (engl. *adaptive neuro-fuzzy inference system*). Razmotren je početni sustav neizrazitog zaključivanja, učenje modela, provjera kvalitete modela te su razmotrena ograničenja, pogreške i nedostaci. Model je praktično primijenjen u programskom okružju na skupu eksperimentalno prikupljenih podataka.

Ključne riječi: urbana mobilnosti, procjena, pokazatelji, indeks, zapis o tarifiranju, telekomunikacije

EXTENDED SUMMARY

The purpose of this PhD thesis was to prove the possibility of application of telecommunication users' activities data (Call Data Records) to suit the needs of providing an urban mobility estimate, then to identify urban mobility indicators, to define the process of their calculation, and define a model which will from the parameters of these indicators give an estimate of urban mobility. The defined goal of my research was to establish a process of the population's urban mobility estimate as a quantitative measure of the process of urban migrations caused by socio-economic activities, one which is in the function of determining a new urban mobility estimation index. A structured record of users' network activities within a public mobile communication network used for the purpose of charging telecommunication

services was used as a primary research material. An algorithm that uses this information as a basis to identify the movement of users within an urban agglomeration covered by this research was developed. Based on the information about the identified migrations, the indicators of urban movement were defined, and the process of their calculation was determined and validated. What then follows is a procedure in which the relation between the values of urban mobility indicators and values of mobility estimation is determined. This relation was defined through the method of surveys. The survey was defined in such a way so that through a number of questions expert opinions could be gathered on how and to what degree the combination of values of certain urban mobility indicators affects mobility. According to their own judgement, experts allocated an appropriate value to each question using the suggested procedure for mobility estimation. The method of fuzzy logic, that is, the ANFIS (*adaptive neuro-fuzzy inference system*) method which functions on the principle of applying conclusion methods which characterise neural networks with the goal of determining parameters of an indirect conclusion system (Fuzzy Inference System – FIS) was used. The result is a system that permits the usage of well-known neural network learning algorithms, ones that cannot be used in fuzzy logic systems, while at the same preserving the possibility of using fuzzy logic. The answers of experts were used as an initial collection of data to establish the model. The model is described with 27 rules, each of which has its own interval of exit mobility estimate values dependent on entry parameter values of entry indicators, defined with a total of 32 fuzzy logic systems which were assigned their appropriate affiliation functions. A form of the exit variable and a learning (optimisation) method as well as the number of epochs were defined. Each of the established fuzzy logic systems were tested for reliability using the RMSE method. The smallest learning mistake was generally observed in all scenarios which used the hybrid learning method and in which the exit function was in linear form. The average model validation error (for a model chosen as optimal) is 0,2103, and the average model validation error is 0,1907. As the most optimal model, the first-class fuzzy logic Sugeno model was chosen, one in which all three entry values are determined with a trapezoid type affiliation function, and each consists of three overlapping linear type functions. A hybrid learning model with three learning epochs was used. The result of the model is an estimate of urban mobility for the matching pair of urban areas (partial mobility index), which is then used to calculate the mobility index of the entire urban agglomeration in the process of urban mobility estimation. Implementation of the urban mobility estimation process was executed using several programming environments. Data collection loading, entry data table conversion and creating the base cell table as well as the

decomposition of space was handled with a programming code developed in the R programming environment. The open source geographic analysis programming tool QGIS was used for space decomposition visualisation. Validation is executed through several steps. Validation of the ANFIS model is part of an integral process of fuzzy logic system forming. What follows then is the validation of algorithms which were defined as part of the mobility validation procedure. The point of validation in this part of the procedure is to confirm that the defined algorithms and the written programming support are correctly calculating the segment they were assigned to. The validation of all algorithms was successful, with which the fact that all written algorithms are properly executing their assigned operations was confirmed. Then comes the model results validation. According to indicator calculation a data segment of 20% for each time frame is extracted, and based on them, partial indexes and the urban mobility index are calculated. Then, the results found in that data are compared with results from the remaining data in the segment, and the discrepancy between results is determined. The procedure of urban mobility estimation was applied on a real publicly available sub-segment of data taken from a record used to charge telecommunication services in a public mobile communication network. The result of the research proves the hypothesis of this scientific research paper which states that **the urban mobility of inhabitants within an urban environment can in a specific time frame be described with an index of urban mobility based on information about recorded telecommunication activities of users in a public mobile communication network.** The goal of the paper was fulfilled and the possibility of telecommunication users' activities data application for the purpose of an urban mobility estimate was proven. Indicators of urban mobility and the process of their calculation were defined, followed by a model which will from the values of these indicators give an estimate of urban mobility. A procedure of the population's urban mobility estimate as a quantitative measure of urban migrations caused by socio-economic activities.

Key words: urban mobility estimation, indicators, index, Call Data Records, telecommunications

Sadržaj

1.	UVOD.....	1
1.1.	PROBLEM ISTRAŽIVANJA I ZNANSTVENA HIPOTEZA	1
1.2.	SVRHA I CILJ ISTRAŽIVANJA	1
1.3.	METODE ISTRAŽIVANJA.....	3
1.4.	PREGLED DOSADAŠNJIH ISTRAŽIVANJA	3
1.5.	KOMPOZICIJA RADA.....	7
2.	URBANA MOBILNOST	10
2.1.	DEFINICIJA URBANE MOBILNOSTI	10
2.2.	EVOLUCIJA URBANE MOBILNOSTI.....	13
2.3.	PROCJENA URBANE MOBILNOSTI TEMELJEM PODATAKA, POKAZATELJA I INDEKSA MOBILNOSTI.....	13
2.4.	IZVORI PODATAKA I PODACI VEZANI UZ URBANU MOBILNOST	15
2.5.	POKAZATELJI URBANE MOBILNOSTI	17
2.5.1.	<i>Općenito o pokazateljima urbane mobilnosti.....</i>	<i>17</i>
2.5.2.	<i>Pokazatelji urbane mobilnosti u literaturi</i>	<i>18</i>
2.5.3.	<i>Pregled pokazatelja po kategorijama</i>	<i>23</i>
2.6.	INDEKSI URBANE MOBILNOSTI.....	26
2.6.1.	<i>Općenito o indeksima urbane mobilnosti.....</i>	<i>26</i>
2.6.2.	<i>Postojeći indeksi urbane mobilnosti u literaturi.....</i>	<i>26</i>
2.7.	ODNOS URBANE MOBILNOSTI I RAZINA USLUGE	29
2.8.	JAVNE POKRETNE KOMUNIKACIJSKE MREŽE I PROCJENA MOBILNOSTI.....	37
2.8.1.	<i>Izvori podataka u pokretnim komunikacijskim mrežama</i>	<i>37</i>
2.8.2.	<i>Područje pokrivanja baznih stanica (dekompozicija prostora)</i>	<i>38</i>
2.8.3.	<i>Postupak kreiranja zapisa za naplatu telekomunikacijskih usluga.....</i>	<i>41</i>
2.8.4.	<i>Depersonalizacija podataka</i>	<i>42</i>
2.8.5.	<i>Dosadašnja istraživanja mobilnosti temeljena na podacima iz javnih pokretnih komunikacijskih mreža.....</i>	<i>44</i>
3.	METODOLOGIJA ISTRAŽIVANJA.....	52
3.1.	PREGLED METODOLOGIJE	52
3.2.	POSTUPAK ODREĐIVANJA INDEKSA URBANE MOBILNOSTI	52
3.2.1.	<i>Ulazni podaci.....</i>	<i>55</i>
3.2.2.	<i>Proračun udaljenosti</i>	<i>57</i>
3.2.3.	<i>Podskupovi podataka.....</i>	<i>59</i>
3.2.4.	<i>Identifikacija putovanja</i>	<i>59</i>
3.2.5.	<i>Spajanje tablica i uklanjanje suvišnih podataka.....</i>	<i>61</i>
3.2.6.	<i>Izračun vrijednosti pokazatelja.....</i>	<i>64</i>

3.2.7.	<i>Izračun parcijalnog indeksa urbane mobilnosti $pIMi,j$</i>	72
3.2.8.	<i>Izračun indeksa urbane mobilnosti</i>	73
3.2.9.	<i>Definiranje i izračun koeficijenta udjela u ukupnoj mobilnosti</i>	74
3.2.10.	<i>Verifikacija i validacija</i>	76
3.3.	UTVRĐIVANJE ODNOSA POKAZATELJA MOBILNOSTI I PROCJENE INDEKSA URBANE MOBILNOSTI	77
3.3.1.	<i>Anketa</i>	77
3.3.2.	<i>Rezultati ankete</i>	89
3.4.	METODA NEIZRAZITE LOGIKE	94
3.4.1.	<i>Neizrazita logika</i>	94
3.4.2.	<i>ANFIS neuronska mreža</i>	103
4.	MODEL INDEKSA URBANE MOBILNOSTI	107
4.1.	RAZVOJ I VALIDACIJA MODELA	107
4.1.1.	<i>Korak 1: Priprema podataka</i>	109
4.1.2.	<i>Korak 2: Generiranje inicijalnog sustava neizrazitog zaključivanja</i>	112
4.1.3.	<i>Korak 3: Učenje ANFIS modela</i>	118
4.1.1.	<i>Korak 4: Validacija i provjera ANFIS modela</i>	121
4.1.2.	<i>Korak 5: Analiza promjene inicijalne FIS strukture i funkcija pripadnosti</i>	124
4.1.3.	<i>Korak 6: Analiza predikcijske pogreške ANFIS modela</i>	127
4.1.4.	<i>Rezultati i komentar modela</i>	130
4.2.	IMPLEMENTACIJA MODELA U PROGRAMSKOM OKRUŽJU	137
5.	PRIMJENA POSTUPKA ODREĐIVANJA INDEKSA URBANE MOBILNOSTI	141
5.1.	IMPLEMENTACIJA POSTUPKA U PROGRAMSKOM OKRUŽENJU	141
5.2.	PRIMJENA POSTUPKA NAD SIMULIRANIM SKUPOM PODATAKA	142
5.3.	PRIMJENA POSTUPKA NAD STVARNIM SKUPOM PODATAKA	145
6.	ZAKLJUČNO RAZMATRANJE	163
	LITERATURA	169
	POPIS SLIKA	178
	POPIS TABLICA	181
	DODACI	184
	DODATAK 1 – ANKETNI UPITNIK NA HRVATSKOM JEZIKU	184
	DODATAK 2 – ANKETNI UPITNIK NA ENGLJSKOM JEZIKU	189

1. UVOD

1.1. Problem istraživanja i znanstvena hipoteza

Mobilnost urbanog stanovništva važan je i sastavni dio društvenog i ekonomskog života koji izravno utječe na gospodarstvo i kvalitetu života, poglavito u velikim urbanim aglomeracijama. Stoga je poznavanje općih značajki urbane mobilnosti vrlo značajno s aspekta organizacije i održivog razvitka prometa u gradovima, s ciljem smanjenja prometnih zagušenja, smanjenja negativnih utjecaja na zdravlje i okoliš te uštedu vremena i troškova vezanih za putovanja.

Urbana mobilnost je mogućnost kretanja pojedinca u urbanom prostoru na organiziran i suvisao način, u skladu s njegovim fiziološkim, intelektualnim i društveno-ekonomskim potrebama, korištenjem postojeće prometne, komunalne i informacijsko-komunikacijske infrastrukture. Mobilnost u gradovima je kroz povijest značajno evoluirala, uglavnom pod utjecajem industrijskih revolucija i općeg društvenog razvoja, tako da je ubrzani razvoj gradova doveo do povećanja broja putnika i količine tereta unutar urbanih područja. Evoluciju mobilnosti karakteriziraju četiri faze. Prva je ona u razdoblju od 1800. do 1880. godine, kada su gradovi uglavnom bili promjera manjeg od pet kilometara, a druga je u razdoblju od 1880. do 1920., kada dolazi do širenja gradova i pojave tramvaja. Slijedi treća faza koja je trajala od 1920. do kraja tisućljeća, a koju karakterizira naglo širenje gradova uz pojavu i masovno korištenje automobila. Sada je u tijeku četvrta faza koja je usmjerena prema održivim oblicima prometovanja, uz snažnu podršku informacijsko-komunikacijskih tehnologija. Intenzivan trend urbanizacije doveo je do toga da je od 1900. godine, kada je samo 2 % svjetske populacije živjelo u urbanom okružju, pa do 2015. godine broj populacije narastao za više od 60 %, uz projekcije da će do 2050. u Europi u urbanom okruženju živjeti 82 % populacije [1,2,3,4]. Širenje gradova i eksponencijalni porast broja stanovnika generira i negativne posljedice mobilnosti, koji se prvenstveno očituju kroz porast eksternih troškova generiranih prometnim sustavom u gradovima te do povećanja broja prometnih nezgoda. Osim toga, dolazi do povećanja negativnih utjecaja na okoliš kroz utrošak energije, emisije štetnih plinova, buku i ostalo. Urbana mobilnost oblikuje se temeljem ekonomskih i društvenih zahtjeva za brzim, povoljnim, sigurnim i učinkovitim prijevozom. Suvremeni pristup rješavanja problema mobilnosti urbanog stanovništva zasniva se na inteligentnim transportnim sustavima, a koji su

temeljeni, prije svega, na korištenju informacijsko-komunikacijskih tehnologija te pomoću njih generiranih podataka.

Urbana mobilnost stanovnika uobičajeno se procjenjuje postupcima usredotočenim na specifične domene (promet, logistika, ekologija, društvo i dr.), uz korištenje domenski ograničenih skupova podataka, pokazatelja i indeksa vezanih za ciljane podskupove ukupne urbane populacije (korisnici javnog prijevoza, biciklisti, vozači i dr.). Cilj i svrha procjene urbane mobilnosti jest identifikacija slabosti i snage prometnog sustava te identifikacija ključnih i/ili kritičnih elementa. Procjenom urbane mobilnosti pruža se uvid u urbanu mobilnost, omogućava se bolje razumijevanje urbane mobilnosti te se stvara temelj za unapređenje postojećih i stvaranje novih usluga u domeni urbane mobilnosti korištenjem pristupa karakterističnih za inteligentne transportne sustave.

Procjena urbane mobilnosti jest postupak koji uključuje pokazatelje i indekse mobilnosti. Pokazatelj urbane mobilnosti definiran je kao veličina temeljena na podacima iz segmenta prometnog sustava, ekonomije, ekologije, društva ili drugih, koja opisuje pojave koje utječu na urbanu mobilnost ili su rezultat urbane mobilnosti, a odnosi se na jedan uski domenski segment. Indeks urbane mobilnosti definiran je kao veličina koja prikazuje integrirani prikaz mobilnosti, a koja je rezultat fuzije odnosnih podataka i/ili pokazatelja urbane mobilnosti.

Procjenom urbane mobilnosti bave se domenski stručnjaci (transport, logistika, ekologija, urbano planiranje) i znanstvena zajednica koja se bavi istraživanjem urbane mobilnosti i razvojem novih usluga vezanih za urbanu mobilnost. Procjenom urbane mobilnosti bavi se i lokalna uprava radi osmišljavanja strategije razvoja mobilnosti, kao i procjenjivanje utjecaja uvođenja planiranih mjera za poboljšanje mobilnosti.

U radu se predlaže novi pristup procjene urbane mobilnosti stanovnika temeljen na podacima o telekomunikacijskoj aktivnosti (glasovni poziv, tekstualna poruka, pristup internetu) korisnika u javnim pokretnim komunikacijskim mrežama. U disertaciji će se koristiti pristup istraživanja urbane mobilnost stanovnika unutar domene inteligentnih transportnih sustava, kao informacijsko-komunikacijske nadgradnje klasičnog sustava prometa i transporta. U istraživanju, pokazatelji urbane mobilnosti izvest će se iz podataka o telekomunikacijskim aktivnostima te će se integrirati u indeks urbane mobilnosti stanovnika.

Sukladno tome, definirana je i znanstvena hipoteza: urbana mobilnost stanovnika u gradskom okruženju, u određenom vremenskom razdoblju, može se opisati indeksom zasnovanim na zapisima o aktivnostima korisnika u javnoj pokretnoj komunikacijskoj mreži.

1.2. Svrha i cilj istraživanja

Svrha istraživanja jest dokazati mogućnost primjene podataka o telekomunikacijskim aktivnostima korisnika za potrebe procjene urbane mobilnosti. U tom smislu identificirat će pokazatelje urbane mobilnosti iz osnovnog skupa podataka, definirati postupak njihova izračuna te zatim definirati model koji će iz vrijednosti tih pokazatelja dati novi indeks kao procjenu urbane mobilnosti.

Cilj istraživanja jest definiranje modela procjene urbane mobilnosti stanovništva kao kvantitativne veličine izvedene iz podataka zasnovanim na zapisima o aktivnostima korisnika u javnoj pokretnoj komunikacijskoj mreži te definiranje novog indeksa za procjenu urbane mobilnosti.

1.3. Metode istraživanja

Zapisi o aktivnostima u javnoj pokretnoj komunikacijskoj mreži (zapisi za naplatu telekomunikacijskih usluga, engl. *Charging Data Records - CDR*) predstavljaju osnovni izvor podataka za istraživanje temeljem kojeg će odgovarajućim postupkom biti izvedeni pokazatelji i indeksi urbane mobilnosti te verificiran i vrednovan postupak procjene urbane mobilnosti stanovnika. Navedeni zapisi uobičajeno se prikupljaju za potrebe naplate telekomunikacijskih usluga. Zapisi o telekomunikacijskim aktivnostima u vlasništvu su operatora javnih pokretnih telekomunikacijskih mreža te mogu sadržavati osjetljive podatke, poput onih o identitetu korisnika. U istraživanju bit će korišteni javno dostupni skupovi podataka namijenjeni akademskom istraživanju, s unaprijed prikrivenim identitetima korisnika.

Iz zapisa o telekomunikacijskim aktivnostima u javnim pokretnim telekomunikacijskim mrežama, bit će ekstrahirani podaci vezani za urbanu mobilnost: vremenski trenutak ostvarenja telekomunikacijske aktivnosti, položaj bazne stanice na koju je korisnik spojen tijekom obavljanja telekomunikacijske aktivnosti (geografska širina i dužina), karakter telekomunikacijske aktivnosti i zamjenska identifikacijska oznaka korisnika koja prikriva stvarni identitet. Temeljem navedenih podataka, bit će definirani sljedeći pokazatelji: broj

putovanja (migracija), vremensko trajanje te (euklidska) udaljenost. Navedeni pokazatelji koristit će se kao ulaz za model. Osim toga, istražiti će se mogućnost definiranja određenih urbanih prostora te će se za te prostore odrediti prethodno navedeni pokazatelji.

Odgovarajućim postupkom iz skupa podataka određuje se matrica putovanja čija polja sadrže ukupan broj migracija između određenog para baznih stanica (ili odgovarajućeg urbanog prostora) u vremenskom okviru. Slijedi određivanje srednje vrijednosti trajanja migracija između parova baznih stanica (odgovarajućeg urbanog prostora) u vremenskom okviru, kao i određivanje euklidske udaljenosti između parova baznih stanica (odgovarajućeg urbanog prostora). Ovaj korak provodi se za sve vremenske okvire za koje se obavlja procjena mobilnosti. U ovom dijelu postupka, iz podataka o telekomunikacijskim aktivnostima korisnika, izračunate su vrijednosti pokazatelja urbane mobilnosti.

U daljnjem tekstu će se za prethodno definirane pokazatelje urbane mobilnosti (broj putovanja, vremensko trajanje te euklidska udaljenost) koristiti i naziv temeljni pokazatelji. Podaci potrebni za definiranje veze između vrijednosti temeljnih pokazatelja i vrijednosti procjene indeksa urbane mobilnosti prikupit će se metodom anketiranja eksperata iz domene urbane mobilnosti. Ovaj postupak je u teoriji ekspertnih sustava poznat kao „crpljenje“ znanja eksperta i njegovo preslikavanje u programsko rješenje ekspertnog sustava (baza znanja, baza pravila). Anketni upitnik sadržavat će pitanja u obliku scenarija koji uključuju vrijednosti temeljnih pokazatelja urbane mobilnosti, definirane na način da obuhvate karakteristične vrijednosti pokazatelja (iz unaprijed definiranih raspona), kao i predloženi postupak za procjenu mobilnosti, koji je temeljen na saznanjima iz znanstvene literature. Eksperti će temeljem vlastite prosudbe svakom scenariju dodijeliti odgovarajuću vrijednost korištenjem predloženog postupka za procjenu mobilnosti. Rezultati anketnog istraživanja osigurat će poveznicu između vrijednosti temeljnih pokazatelja iz scenarija i vrijednosti procjene mobilnosti. Navedeni skup podataka koristit će se za formiranje ekspertnog sustava za procjenu urbane mobilnosti. Za definiranje modela procjene mobilnosti koristit će se logički sustav neizrazite logike, odnosno ANFIS (engl. *adaptive neuro-fuzzy inference system*), kao višeslojni prilagodljivi sustav neizrazitog zaključivanja zasnovan na neuronskoj mreži, koji je danas vrlo raširen kao jedna od vrsti ekspertnih sustava.

Temeljem rezultata provedenih istraživanja te rezultata postupka neizrazitog zaključivanja, bit će razvijen model za procjenu urbane mobilnosti korištenjem temeljnih pokazatelja izvedenih iz zapisa o telekomunikacijskim aktivnostima korisnika javnih pokretnih

telekomunikacijskih mreža. Model će omogućiti procjenu urbane mobilnosti korištenjem temeljnih pokazatelja urbane mobilnosti: broj migracija, vremensko trajanje i euklidska udaljenost, temeljenih na informacijama o telekomunikacijskim aktivnostima korisnika javnih pokretnih telekomunikacijskih mreža.

Analizom rezultata provjerit će se hipoteza i također identificirati mogući nedostaci koji proizlaze iz specifične prirode urbane mobilnosti pojedinih gradova (lokalna tradicija, običaji, društveno-ekonomski karakter i slično).

Za potrebe istraživanja koristit će se programsko okruženje za statističku analizu, modeliranje i simulacije „R“ u kojem će biti razvijena programska podrška za proračun pokazatelja urbane mobilnosti te programsko okruženje Matlab za razvoj modela temeljenog na neizrazitom zaključivanju. Za potrebe geoprostorne analize podataka, bit će korišteno programsko okruženje QGis, a za dio prikaza podataka i obradu rezultata ankete programsko okruženje Microsoft Excel.

1.4. Pregled dosadašnjih istraživanja

Dosadašnja istraživanja pokazala su da se urbana mobilnost općenito procjenjuje na način da se prvo identificiraju relevantni pokazatelji urbane mobilnosti, a potom se formira indeks urbane mobilnosti (procjena urbane mobilnosti). Prvi korak pri izračunu pokazatelja urbane mobilnosti jest identifikacija i prikupljanje podataka o urbanoj mobilnosti [5,6].

Podaci o urbanoj mobilnosti su heterogene prirode i prikupljaju se iz različitih izvora koji se načelno dijele u tri grupe [7]. Prva grupa su konvencionalni izvori podataka koji uključuju uvriježene izvore podataka, kao što su osjetila na prometnoj infrastrukturi, meteorološka osjetila, ekološka osjetila i slično [6]. U drugu grupu izvora podataka spadaju informacijsko-komunikacijski sustavi sudionika u urbanoj mobilnosti. Primjer takvih sustava je sustav za naplatu korištenja cestovne infrastrukture, zatim sustav za pametne kartice javnog gradskog prijevoza putnika i drugi [8]. Treću grupu podataka čine tzv. novi izvori podataka koji obuhvaćaju korištenje relativno novih tehnologija, a čija primjena u procjeni urbane mobilnosti još nije široko korištena (npr. javne pokretne telekomunikacijske mreže, društvene mreže, autonomna vozila) [9-14]. Primarna funkcija izvora podataka iz druge i treće grupe nije prikupljanje ili generiranje podataka o urbanoj mobilnosti, ali uslijed prirode rada takvih sustava, oni mogu generirati podatke koji su iskoristivi za procjenu urbane mobilnosti. Na

primjer, zapisi o telekomunikacijskim aktivnostima korisnika u javnoj pokretnoj telekomunikacijskoj mreži primarno se koriste za naplatu telekomunikacijskih usluga. Međutim, odgovarajućim postupcima iz tih podataka je moguće ekstrahirati informacije koje mogu biti korisne za procjenu urbane mobilnosti. Ovo pruža mogućnost razvoja novih poslovnih mogućnosti za operatore mobilne telefonije jer se stvara temelj za pružanje novih usluga, od kojih jedna može biti i procjena urbane mobilnosti.

Općenito, pokazatelji urbane mobilnosti dijele se u pet grupa. Prometni pokazatelji prikazuju urbanu mobilnost kroz kategorije koje su vezane za prometni aspekt (npr. vrijeme putovanja, brzina putovanja, matrice putovanja i slično) [15]. Ekonomski pokazatelji pokazuju utjecaj pojedinih ekonomskih komponenti na urbanu mobilnost (npr. cijena litre goriva, cijena parkiranja, primanja kućanstva i slično) [16]. Društveni pokazatelji prikazuju urbanu mobilnost kroz njezinu društvenu prihvatljivost (npr. broj nesreća, broj smrtno stradalih i slično) [17]. Okolišni pokazatelji prikazuju urbanu mobilnost kroz kategorije koje su vezane za okoliš i meteorološke uvjete (npr. emisija polutanata, buke) [18]. Dodatni pokazatelji su oni koje nije moguće svrstati niti u jednu od prethodno navedenih kategorija (npr. postojanje regulatornih okvira, tijela za upravljanje ili planiranje mobilnošću, urbanizam, demografija i slično) [19].

Kao jedan od izvora podataka iz kategorije takozvanih novih izvora jesu i podaci iz javnih pokretnih komunikacijskih mreža, čiji je potencijal prepoznao velik broj autora, a koji su detaljno obrađeni u poglavlju 2.8.5. Razlog korištenja tog skupa podataka jest to što eliminira nedostatke uobičajenih metoda prikupljanja podataka o urbanoj mobilnosti (ankete, istraživanje navika, mjerenja na ograničenom prostoru ili presjeku) koje su se pokazale kao ekonomski neefikasne jer koriste malen uzorak ispitanika, imaju ograničeno prostorno i vremensko pokrivanje te se provode u često neodgovarajućim vremenskim intervalima (veliki razmaci između prikupljanja podataka). Uopćeno, zaključak je da taj izvor podataka predstavlja veliki potencijal u istraživanju urbane mobilnosti, prvenstveno jer obuhvaća veoma visok uzorak stanovništva, a povezan s informacijama o položaju baznih stanica može djelomično rekonstruirati i kretanje korisnika. Također, povećanjem broja korisnika mobilnih telefona smanjena je i gotovo u potpunosti eliminirana razlika između broja osoba koje imaju mobilni telefon i onih koji ih nemaju, čime je ovaj izvor podataka postao još prikladniji za istraživanje mobilnosti [20].

Najznačajniji i najzastupljeniji indeksi urbane mobilnosti u znanstvenoj literaturi su indeks vremena putovanja (engl. *Travel Time Index* – TTI) razvijen na Transportnom institutu

u Texasu [21], zatim indeks mobilnosti (engl. *Mobility Index*) razvijen na sveučilištu Imperial College u Londonu [22], te uzorkovani indeks mobilnosti (engl. *Sampling mobility index* – SMI) autora F. Freia [23]. Indeks urbane mobilnosti „Travel Time Index – TTI“ predstavlja indeks vremena putovanja. Koristi se za mjerenje razlika u zagušenju u prometu među metropolitanskim područjima, odnosno vezan je za brzinu prometnog toka. Indeks vremena putovanja računa se kao količnik vremena potrebnog za putovanje tijekom zagušenja i vremena potrebnog za prolazak iste dionice u razdoblju bez zagušenja. Indeks urbane mobilnosti „Mobility Indeks“ za ocjenu urbane mobilnosti koristi veličine, kao što su prosječno vrijeme putovanja na određenoj dionici korištenjem sustava javnog gradskog prijevoza i osobnog automobila, normalizirane udaljenošću između početka i kraja dionice te ponderirano težinskim faktorom dobivenim ekspertnom metodom. Indeks urbane mobilnosti „Sampling mobility index“ namijenjen je procjeni urbane mobilnosti u malim i srednjim urbanim okružjima. Značajan je jer predstavlja prvi široko prihvaćen postupak za procjenu mobilnosti korištenjem indeksa. Uzima u obzir samo pokazatelje koji su vezani za infrastrukturu, što predstavlja značajan nedostatak. Određen je sa osam pokazatelja koji se potom objedinjuju u osam indeksa, po jedan za svaki kriterij. Tih osam indeksa potom se ujedinjuju u jedan integrirani indeks. Ovaj indeks urbane mobilnosti predstavlja primjer indeksa koji integrira više indeksa mobilnosti. Zaključak je da ne postoji opće prihvaćeni indeks za procjenu urbane mobilnosti. Postojeći pokazatelji i indeksi urbane mobilnosti uglavnom su ciljano razvijani za određene gradove ili urbana područja, uzimajući u obzir lokalne specifičnosti, tako da je njihova primjena ograničena samo na to područje. Izbor pokazatelja urbane mobilnosti uglavnom je vezan za dostupnost podataka, odnosno postojanje određenog izvora podataka, što ograničava objektivno i usporedivo ocjenjivanje mobilnosti stanovnika urbanih aglomeracija u kojima takvi podaci, odnosno izvori, ne postoje. Također, za procjenu urbane mobilnosti uglavnom se koriste konvencionalni izvori podataka, a potencijal „novih“ izvora podataka nije dovoljno iskorišten.

1.5. Kompozicija rada

Doktorski rad sastoji se od šest poglavlja: literature, priloga, popisa tablica, popisa slika te dodataka. Rad sadrži i dodatne materijale (programski kod, ulazne i izlazne skupove podataka), koji su priloženi na mediju u elektroničkom obliku.

Rad je podijeljen u sljedeća poglavlja:

- Uvod
- Urbana mobilnost
- Metodologija istraživanja
- Model indeksa urbane mobilnosti
- Primjena postupka određivanja indeksa urbane mobilnosti
- Zaključak.

U uvodnom dijelu rada opisan je predmet, odnosno problem istraživanja, definirana je znanstvena hipoteza te svrha i cilj istraživanja. U nastavku je prezentiran pregled dosadašnjih istraživanja te su navedene i opisane znanstvene metode korištene u istraživanju. U završnom dijelu uvoda prikazana je struktura rada prema tematskim cjelinama.

U drugom poglavlju (Urbana mobilnost) predstavljen je pregled definicija urbane mobilnosti, kao i pregled evolucije urbane mobilnosti. Analizirani su dosadašnji postupci procjene urbane mobilnosti temeljem podataka, pokazatelja i indeksa urbane mobilnosti, naveden je pregled izvora podataka, pokazatelja i dosadašnjih indeksa urbane mobilnosti. Prikazan je odnos urbane mobilnosti i razina usluga te su predstavljene javne pokretne komunikacijske mreže kao izvor podataka za procjenu urbane mobilnosti.

U trećem poglavlju (Metodologija istraživanja) prikazan je pregled metodologije i definiran je postupak određivanja indeksa urbane mobilnosti. Postupak određivanja mobilnosti sastoji se od deset koraka, počevši od definiranja ulaznog skupa podataka pa do validacije. U ovom poglavlju predstavljeni su i rezultati anketnog istraživanja te su utvrđeni odnosi između predloženih pokazatelja mobilnosti i procjene mobilnosti. Definiran je teorijski okvir za primjenu koncepta neizrazite logike, odnosno za primjenu tehnike strojnog učenja ANFIS.

U četvrtom poglavlju (Model indeksa urbane mobilnosti) izvršen je razvoj i validacija modela, generiran je inicijalni sustav neizrazitog zaključivanja, izvršeno je učenje ANFIS modela, validacija i provjera ANFIS modela, zatim analiza promjene inicijalnog sustava neizrazitog zaključivanja i funkcija pripadnosti, analiza predikacijskih pogrešaka modela, te su predstavljeni rezultati i komentar modela. Izvršena je i implementacija modela u programskom okružju.

U petom poglavlju (Primjena postupka određivanja indeksa urbane mobilnosti) izvršena je implementacija cjelokupnog postupka procjene mobilnosti u programskom okružju.

Postupak je primijenjen nad stvarnim skupom podataka. U ovom koraku izvršena je i validacija postupka procjene urbane mobilnosti.

U šestom poglavlju (Zaključak) prikazana su zaključna razmatranja kroz sažet pregled provedenog znanstvenog istraživanja. Zaključak sadrži rezultate istraživanja te pregled osnovnih značajki razvijenog modela, kao i pregled postupka procjene urbane mobilnosti. Poglavlje završava pregledom mogućnosti primjene modela te smjernicama za nastavak istraživanja.

2. URBANA MOBILNOST

2.1. Definicija urbane mobilnosti

Znanstvena zajednica mobilnost proučava s više aspekata, a o tome ovise i definicije mobilnosti. Većina autora slaže se oko osnovne poopćene definicije urbane mobilnosti koja kaže da mobilnost u urbanom okruženju predstavlja kretanje i da je zadaća mobilnosti osigurati pristup željenim destinacijama korištenjem različitih prijevoznih sredstava [24]. Urbana mobilnost predstavlja kretanje osoba između različitih izvorišta i odredišta, u različitim vremenskim razdobljima, korištenjem različitih prijevoznih sredstava i načina putovanja, a u svrhu ostvarivanja različitih ciljeva [25]. Kretanje osoba može se podijeliti po svrsi kretanja, po vremenskoj distribuciji kretanja, po odabiru načina putovanja, po duljini kretanja ili po prostornim karakteristikama kretanja. Urbana kretanja po svrsi se mogu podijeliti na obigatorna i voluntarna. Obligatorna putovanja uključuju pendularna putovanja (putovanja koja vežu kuću i mjesto rada), profesionalna putovanja (vezana su za radno mjesto) i distribucijska putovanja (putovanja u svrhu distribucije kretanja). Voluntarna putovanja su obično osobna putovanja (na mjesta komercijalnih aktivnosti, kulturna događanja i rekreaciju) i turistička putovanja (povijesni, sportski i/ili slični motivi) [25], [26]. Putovanja se po svrsi ili namjeni putovanja, a u funkciji aktivnosti koju pojedina osoba poduzima, mogu svesti na odlazak na posao i povratak, kupovinu, društvene aktivnosti, rekreaciju, obrazovanje, poslovna kretanja i putovanja uslijed zdravstvenih potreba [25], [26]. U smislu vremenske distribucije putovanja, razlikujemo putovanja tijekom dnevnih vršnih opterećenja (uglavnom odlasci i dolasci s posla), zatim putovanja koja su vezana za kupovinu ili društvene aktivnosti, i koja su istaknuta između dnevnih vršnih opterećenja i tijekom kasnih poslijepodnevni i noćnih sati. Treća karakteristika kretanja putnika je odabir načina putovanja i odgovarajućeg prijevoznog sredstva, odnosno njihovih kombinacija. Putovanja su karakterizirana i prema duljini putovanja. Duljina putovanja ili prijeđeni put ovise o broju stanovnika, gustoći stanovanja, površini grada i atraktora. Na samom kraju, prostorna distribucija putovanja definira mobilnost u ovisnosti o prostornoj urbanoj strukturi, kao i o prostornim karakteristikama prometnog sustava [25], [26].

U ovisnosti o autorima i stanovištu s kojeg izučavaju urbanu mobilnost, mobilnost je moguće definirati i na druge načine.

Prema Gillisu i suradnicima [27], mobilnost uključuje kretanje i prijevoz, i osoba i tereta, na području urbane aglomeracije. Mobilnost uključuje sve načine prijevoza koji su relevantni za gradski promet (motorizirane i nemotorizirane, javne i osobne načine prometovanja), kao što su: brodovi, helikopteri, vlakovi, laka željeznica, podzemna željeznica, trolejbusi, žičare, tramvaji i autobusi, različite vrste automobila, motocikli, mopedi, bicikli, električni bicikli i pješčenje. Mobilnost uključuje i sve relevantne strukture; od donosioca odluka, preko pružatelja usluga pa do samih krajnjih korisnika.

Kuhlike i Yuand mobilnost po vrsti dijele na više kategorija, tako da razlikuju fizičko kretanje u urbanom prostoru (putovanja radi posla, zabave ili u neke druge svrhe), fizičko kretanje objekata (paketi, kontejneri), imaginarnu mobilnost (sjećanja, knjige, filmovi), vizualnu mobilnost (virtualni atlasi poput Google Eartha, itd.) i komunikacijsku mobilnost (pisma, videokonferencije, e-mailovi, itd.) [24].

Prema Caseyu i suradnicima mobilnost je definirana vremenom i troškovima povezanim s putovanjem. Mobilnost je veća kada su prosječna vremena putovanja, odstupanja u vremenu putovanja i troškovi putovanja niži [28].

Prema Costi i suradnicima, mobilnost je svojstvo pojedinca koje omogućava putovanja u prostoru. Ograničena je dimenzijama urbanog prostora i pod utjecajem složenih aktivnosti koje se provode u tom prostoru. Na mobilnost mogu utjecati i karakteristike pojedinca, kao što su dob, spol i primanja, kao i karakteristike urbanog okoliša i dostupnost prijevozne usluge [29].

Prema Brčiću i suradnicima [25], [30], ukupna mobilnost vezana je za osobu i predstavlja ukupan broj putovanja unutar promatranog područja, bez obzira na način putovanja i svrhu putovanja, koje se uobičajeno promatra u jednom danu. Mobilnost stanovnika se često izražava kao broj putovanja u promatranom razdoblju po stanovniku. Mogući su pojmovi: "stopa mobilnosti" koja izražava broj putovanja po osobi na dan, "ukupna duljina mobilnosti" koja izražava broj prijeđenih putnih kilometara po osobi u jedinici vremena i "ukupno vrijeme mobilnosti" koje je iskazano kao broj sati potrošenih na putu po osobi u jedinici vremena. Često se mobilnost izražava kao broj putnih kilometara vozila, što je još kompleksnija izvedenica. Također, Brčić dijeli urbanu mobilnost, kao fizičko kretanje u urbanom prostoru u tri kategorije, i to u javni gradski prijevoz, individualni prijevoz i teretni promet. Pritom je javni gradski prijevoz u funkciji omogućavanja mobilnosti svim društvenim kategorijama stanovnika. Njegova je efikasnost temeljena na prijevozu velikog broja ljudi i prihvatljive ekonomske

racionalnosti. Uključuje podsustave kao što su taksi, paratranzit, tramvaji, autobusi, trolejbusi, LRT, metro, trajekti i slično. Individualna mobilnost uključuje bilo koji način kretanja gdje je to kretanje produkt osobnog izbora načina korištenja kretanja. Kretati se u smislu mobilnosti može korištenjem osobnog vozila, pješaćenjem, korištenjem bicikla i motocikla. Mobilnost tereta je produkt potreba stanovnika urbane forme za egzistencijalnim potrebama, a grad je, u pravilu, centar produkcije i potrošnje.

Prema Rashidyu i suradnicima urbana mobilnost može imati dvije dimenzije. Prva dimenzija mobilnosti odnosi se na perspektivu korisnika i opisuje mogućnost kretanja s jednog mjesta (izvor) na drugo mjesto (odredište) korištenjem odgovarajućeg načina prijevoza. Druga dimenzija na mobilnost gleda s razine infrastrukture, pri čemu je mobilnost definirana kao mogućnost prometnog sustava da osigura pristup poslu, edukaciji, zdravstvenim uslugama, trgovini i sličnom, pri čemu korisnici mogu stići do svojih odredišta odgovarajućim prijevoznim sredstvom sa zadovoljavajućom razinom usluge. Stoga, Rashidy mobilnost definira kao mjeru učinkovitosti prometnog sustava pri povezivanju prostorno odvojenih lokacija, pri čemu se mobilnost koristi kao ključni pokazatelj uspješnosti funkcionalnosti prometnog sustava [31].

Gudmundsson sa suradnicima definira razliku mobilnosti od transporta. Mobilnost predstavlja širi koncept od transporta jer se ne odnosi samo na stvarno kretanje, već i na potencijal kretanja, odnosno na prostorni, gospodarski i društveni kontekst kretanja. Stoga, pojam mobilnosti je po analogiji sveobuhvatniji pojam od transporta. Definira mobilnost kao mogućnost pristupa željenom odredištu relativnom lakoćom, u razumnom vremenu, s razumnim troškom i željenim načinom prijevoza [32].

Litman mobilnost definira kao kretanje osoba i tereta, pri čemu se mobilnost dimenzionira putničkim ili tonskim kilometrima te brojem putovanja. Mobilnost kao kretanje nije cilj sam po sebi, već je mobilnost sredstvo za postizanje cilja. Litman smatra da svako povećanje broja putovanja, putničkih ili tonskih kilometara te brzini putovanja ili prijevoza pozitivno doprinosi mobilnosti [19], [33], [34].

Kaparias sa suradnicima [35] definira mobilnost kao ključni element transportnog sustava, odnosno kao sposobnost prometnog sustava u osiguranju pristupa poslu, rekreaciji, trgovini i intermodalnim transfernim točkama, kao i područjima drugih namjena. Mobilnost izražava lakoću kretanja uopćeno, na razini cjelokupne urbane aglomeracije ili na odgovarajućim, predefiniranim rutama koje povezuju određene parove izvora i odredišta, bez obzira na vrstu načina prijevoza kojima se korisnik služi. Kaparias smatra da se mobilnost može

prikazati raznovrsnim pokazateljima, ali osnovni pokazatelji mobilnosti svode se na prosječno vrijeme putovanja do željenog odredišta izraženog u jedinici vremena, normaliziranog udaljenošću te ponderirano faktorima u ovisnosti o cilju ocjenjivanja mobilnosti.

Prema Abramoviću i suradnicima [36], mobilnost podrazumijeva srednji broj putovanja po stanovniku u jedinici vremena. Mobilnost se može određivati i za određene skupine ljudi i tada možemo govoriti o radnoj mobilnosti ili mobilnosti studenata ili učenika. Ona se može iskazivati i za stanovnike određenog područja (grada, predgrađa ili šireg područja i slično) i tada je riječ o mobilnosti u gradskom, prigradskom ili međugradskom prijevozu. Najčešće su vremenske jedinice za koje se iskazuje mobilnost godina, mjesec ili dan, odnosno radi se o godišnjoj, mjesečnoj ili dnevnoj mobilnosti. Mobilnost je veća tamo gdje je društvo razvijenije, gdje je standard stanovnika viši i gdje je kvaliteta prometnog sustava bolja. Dakle, mobilnost raste s razvijenošću društva.

Obzirom na više različitih definicija mobilnosti, za potrebe ove disertacije će se koristiti izvedenica koja kaže:

Urbana mobilnost je definirana kao mogućnost kretanja pojedinca u urbanom prostoru na organiziran i suvisao način sukladno njegovim fiziološkim, intelektualnim i društveno-ekonomskim potrebama, korištenjem postojeće prometne, komunalne i informacijsko-komunikacijske infrastrukture.

2.2. Evolucija urbane mobilnosti

Mobilnost je kroz povijest značajno evoluirala, uglavnom pod utjecajem industrijskih revolucija i općeg društvenog razvoja. Ubrzani razvoj gradova doveo je do povećanja broja putnika i količina tereta unutar urbanih područja. Dužina putovanja u prostoru se povećala, ali korištenje novih načina prijevoza osigurava da je vremensko trajanje prosječnog putovanja uglavnom konstantno, bez obzira što se njima prevaljuje veća udaljenost. U razvijenim zemljama možemo identificirati četiri ere razvoja urbanih okružja (gradova), od kojih svaku karakterizira odgovarajući oblik urbane mobilnosti [26].

Prva era urbane mobilnosti smješta se u razdoblje od 1800. do 1880. godine. Prvu eru urbane mobilnosti karakterizira korištenje modova prijevoza, kao što su pješaćenje i korištenje konjskih zaprega. Gradovi su uglavnom bili promjera manjeg od 5 km, tako da je od središta

grada do periferije bilo moguće doći za 30-ak minuta. Namjena zemljišta je mješovita, uz gustoću od 100 do 200 stanovnika po hektaru. Grad je kompaktan i uglavnom kružnog oblika. Javni gradski prijevoz je dostupan u obliku omnibusa (konjskog tramvaja), koji je omogućio širenje gradova, ali bez promjene u strukturi. Prva promjena u strukturi grada uzrokovana je pojavom željeznice. Karakterizirana je pojavom predgrađa, odnosno proširenja naselja uz prugu, koji su upravo prugom odvojeni od samog grada i međusobno. Naselja se uglavnom šire u blizini željezničkih stanica, i od gradskog centra su udaljeni na do pola sata vožnje željeznicom [26].

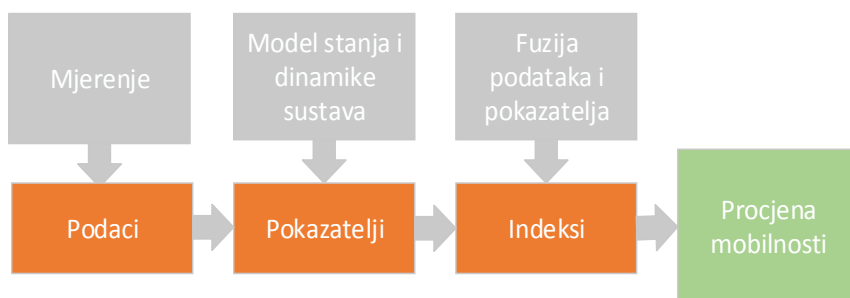
Druga era urbane mobilnosti naziva se erom električnog tramvaja (1880. do 1920.). Izum električne vuče je doveo do revolucije u urbanoj mobilnosti. Prva linija električnog tramvaja je otvorena u Sankt Peterburgu 1880. godine, a potom slijede uvođenja u Berlinu, Londonu i SAD-u. Revolucija se očitovala u brzini vožnje jer je električni tramvaj postizao trostruko veću brzinu od konjskog tramvaja. Razvoja gradova pratio je razvoj pruge električnog tramvaja, tako da gradovi rastu u promjeru na 20 do 30 km, a pritom uslijed neravnomjernog širenja uz prugu postaju nepravilnog, najčešće zvjezdastog oblika. Centar grada ostaje područjem mješovite namjene sa zadržavanjem razine gustoće stanovništva po hektaru, dok gustoća u predgrađima i rubnim dijelovima grada pada na 50 do 100 stanovnika po hektaru [26].

Treća era urbane mobilnosti nastala je masovnijom pojavom automobila i traje od 1920. do kraja tisućljeća. Premda su automobili prisutni od kraja 19 stoljeća, tek je početkom dvadesetih godina dvadesetog stoljeća, njihovom masovnom proizvodnjom, automobil postao dostupan širim masama. To je uzrokovalo i promjenu obrasca namjene zemljišta, tako da se grad počinje širiti preko „zelenih“ dijelova koji su ostali neiskorišteni između predgrađa nastalih uz prugu. U tom razdoblju javni gradski prijevoz putnika iz privatnog sektora, koji postaje neisplativ, seli u javni sektor te se javlja koncept subvencioniranog javnog prijevoza u vlasništvu grada. Postupno dolazi do sve veće popularizacije osobnog automobila, koji postaje dominantno sredstvo prijevoza u gradovima širom svijeta. Automobil je riješio problem prelaska većih udaljenosti u kratkom vremenu, što je dovelo do masovnog i nekontroliranog urbanog širenja, kao i do prilagodbi infrastrukture korištenju osobnog automobila [26].

Sada je u tijeku takozvana četvrta faza urbane mobilnosti. Trenutna faza favorizira održive oblike prometovanja, koja uvodi nove koncepte vlasništva vozila, nove vrste alternativnih prijevoznih sredstava i nove vrste ekološki prihvatljivih vozila, a sve uz snažnu podršku informacijsko-komunikacijskih tehnologija [37].

2.3. Procjena urbane mobilnosti temeljem podataka, pokazatelja i indeksa mobilnosti

Galileo Galilei je napisao: „Broji ono što se može brojiti, mjeri ono što se može mjeriti, a što nije mjerljivo, učini mjerljivim“ [38]. Kako bi se identificirale slabosti i snage prometnog sustava, identificirali ključni ili kritični elementi, pružio uvid u urbanu mobilnost, omogućilo bolje razumijevanje urbane mobilnosti, te stvorio temelj za unaprijeđene postojećih i stvaranje novih usluga u domeni inteligentnih transportnih sustava, urbanu mobilnost je potrebno procijeniti. Dosadašnji pristupi procjene urbane mobilnosti svode se na korištenje postupaka koji uključuju pokazatelje i indekse mobilnosti [9], [22], [27], [34], [39]. Pokazatelj urbane mobilnosti je definiran kao veličina temeljena na podacima iz segmenta prometnog sustava, ekonomije, ekologije, društva ili drugih, koja opisuje pojave koje utječu na urbanu mobilnost ili su rezultat urbane mobilnosti. Indeks urbane mobilnosti je definiran kao veličina koja je rezultat fuzije odnosnih podataka i/ili pokazatelja urbane mobilnosti s ciljem dobivanja procjene urbane mobilnosti [40]. Urbana mobilnost se općenito procjenjuje na način da se prvo identificiraju relevantni pokazatelji urbane mobilnosti, a potom se formira indeks urbane mobilnosti (procjena urbane mobilnosti).



Slika 1. Elementi procesa ocjenjivanja mobilnosti, obrada autora temeljem [41]

Kao što je prikazano na slici 1., mjerenjem se dobivaju mjerne vrijednosti, koje služe za uspostavljanje definiranih pokazatelja, a primjenom odgovarajuće metodologije uspostavljaju se indeksi koji služe za konačno ocjenjivanje mobilnosti. Prvi korak pri izračunu pokazatelja urbane mobilnosti jest identifikacija i prikupljanje podataka o urbanoj mobilnosti [5], [6].

2.4. Izvori podataka i podaci vezani uz urbanu mobilnost

Podaci o urbanoj mobilnosti su heterogene prirode i prikupljaju se iz različitih izvora koji se načelno dijele u tri grupe [7]. Konvencionalni izvori podataka uključuju uvriježene izvore podataka, kao što su osjetila na prometnoj infrastrukturi, meteorološka osjetila, ekološka

osjetila i slično [6]. U drugu grupu izvora podataka spadaju informacijsko-komunikacijski sustavi sudionika u urbanoj mobilnosti (organizacije koje se bave pružanjem usluga javnog gradskog prijevoza putnika, naplatom infrastrukture i slično). Primjer takvih sustava je sustav za naplatu korištenja cestovne infrastrukture, zatim sustav za pametne kartice javnog gradskog prijevoza putnika i drugi [8]. Treću grupu podataka čine tzv. novi izvori podataka, koji obuhvaćaju primjenu relativno novih tehnologija, a čija primjena u procjeni urbane mobilnosti još nije široko korištena (npr. javne pokretne komunikacijske mreže, društvene mreže, autonomna vozila) [9]–[14]. Primarna funkcija izvora podataka iz druge i treće grupe nije prikupljanje ili generiranje podataka o urbanoj mobilnosti, ali uslijed prirode rada takvih sustava oni mogu generirati podatke koji su iskoristivi za procjenu urbane mobilnosti. Na primjer, zapisi o telekomunikacijskim aktivnostima korisnika u javnoj pokretnoj komunikacijskoj mreži primarno se koriste za naplatu telekomunikacijskih usluga. Međutim, odgovarajućim postupcima iz tih podataka je moguće ekstrahirati informacije koje mogu biti korisne za procjenu urbane mobilnosti. Popis izvora podataka po kategorijama dan je u tablici 1.

Tablica 1. Popis izvora podataka koji se mogu koristiti u svrhu procjene mobilnosti

Konvencionalni izvori podataka	Informacijsko-komunikacijski sustavi dionika	Nekonvencionalni izvori podataka
Pneumatski brojači prometa	Naplata korištenja cestovne infrastrukture	Javne pokretne komunikacijske mreže
Piezoelektrični senzori	Naplata korištenja parkirališne infrastrukture	Satelitske fotografije
Induktivne petlje prometa	Sustav javnih bicikala	Društvene mreže
Radarski brojači prometa	Sustav javnih automobila	Samovozeća vozila
Infracrveni brojači prometa	Sustav dijeljenja automobila	Povezana vozila
Magnetski brojači prometa	Baza podataka prometnih nesreća	Navigacijski uređaji
Ultrazvučni brojači prometa	Baza podataka registriranih vozila	Ugrađeno računalo u vozilu
Video brojači prometa	Javni gradski prijevoz putnika	
Popis stanovništva	Pametne kartice za naplatu JGPP-a	
Ekološka osjetila		
Meteorološka osjetila		
Ručno brojanje		
Opažanje		
Ankete		

Temeljem: [6]–[14]

2.5. Pokazatelji urbane mobilnosti

2.5.1. Općenito o pokazateljima urbane mobilnosti

Pokazatelj (engl. *indicator*) je opći naziv za veličinu koja pokazuje stanje ili promjenu stanja nekog sustava, odnosno odvijanje procesa. Pokazatelji služe za prikaz stanja sustava u odnosu na željeno stanje, ukazuju na napredak sukladno ciljevima te prikazuju trenutni status svim zainteresiranim stranama [16]. Pokazatelj omogućava učinkovito i jednostavno praćenje promjena tijekom određenog vremenskog razdoblja. Cilj pokazatelja je prikazati mobilnost i trendove promjena na sažet, jednostavan i razumljiv način [42].

Temeljem odgovarajućih (dostupnih) podataka iz segmenta prometnog sustava, ekonomije, ekologije, društva i/ili drugih, formiraju se pokazatelji urbane mobilnosti. Općenito, pokazatelji urbane mobilnosti dijele se u pet grupa. Prometni pokazatelji prikazuju urbanu mobilnost kroz kategorije koje su vezane za prometni aspekt (npr. vrijeme putovanja, brzina putovanja, matrice putovanja, itd.) [15]. Ekonomski pokazatelji pokazuju utjecaj pojedinih ekonomskih komponenti na urbanu mobilnost (npr. cijena litre goriva, cijena parkiranja, primanja kućanstva, itd.) [16]. Društveni pokazatelji prikazuju urbanu mobilnost kroz njezinu društvenu prihvatljivost (npr. broj nesreća, broj smrtno stradalih, itd.) [17]. Okolišni pokazatelji prikazuju urbanu mobilnost kroz kategorije koje su vezane za okoliš i meteorološke uvjete (npr. emisija polutanata, buke) [18]. Dodatni pokazatelji su oni koje nije moguće svrstati niti u jednu od prethodno navedenih kategorija (npr. postojanje regulatornih okvira, tijela za upravljanje ili planiranje mobilnošću, urbanizam, demografija, itd.) [19].

Prilikom formiranja pokazatelja, potrebno je izabrati one koji zadovoljavaju sljedeće kriterije [19], [33]. Pokazatelj mora biti:

- opsežan (imati utjecaj na prometne, ekonomske, društvene i okolišne veličine),
- temeljen na kvalitetnim podacima (prikupljanje i obrada podataka mora zadovoljiti znanstvene standarde kako bi se osigurala točnost i konzistentnost),
- usporediv (metodologija prikupljanja podatka treba biti standardizirana kako bi se omogućila komparacija),
- statistički i znanstveno validan,
- vremenski i geografski određen [16], [42],
- otporan na utjecaje,

- razumljiv (mora biti koristan donosiocima odluka i jasan općoj javnosti) [43],
- prilagođen specifičnostima različitih lokacija, kultura, navika i institucija i
- troškovno učinkovit (proces prikupljanja i obrade podataka ne smije biti veći od koristi koju oni donose).

2.5.2. Pokazatelji urbane mobilnosti u literaturi

U znanstvenoj literaturi pokazatelji urbane mobilnosti su detaljno obrađeni. U nastavku slijedi prikaz pokazatelja u najznačajnijoj literaturi iz tog područja.

Litman [19], [34] pokazatelje grupira u sljedeće kategorije: ekonomski, društveni i ekološki. U grupu važnih pokazatelja u kategoriji ekonomskih pokazatelja smješta mobilnost po glavi stanovnika, modalna razdioba, prosječno vrijeme putovanja na posao, prosječnu brzinu kretanja teretnog prometa, troškove zagađenja po glavi stanovnika, ukupna davanja na transport po glavi stanovnika. U kategoriju društvenih pokazatelja spada broj nezgoda i smrtno stradalih po osobi, prilagođenost prometnog sustava karakterističnim skupinama korisnika, financijska pristupačnost, opće zadovoljstvo prometnim sustavom, prilagođenost osobama s posebnim potrebama. U kategoriju okolišnih pokazatelja smješta utrošak energije po glavi po modu prometa, potrošnju energije po tonskom kilometru, zagađenje zraka po glavi stanovnika, zauzeće zemljišta za potrebe prometa po glavi stanovnika, zagađenost zrakom i bukom, pokrivenost površine i upravljivost oborinskim vodama. U grupu opcijskih pokazatelja u kategoriji ekonomskih pokazatelja nalazi se relativna kvaliteta nemotoriziranog prometa te broj javnih usluga i prilika za posao u dosegu od 10 minuta pješaćenjem ili 20 minuta putovanja nekim drugim sredstvom. Opcijski društveni pokazatelji uključuju udio osoba koje dnevno šeću ili koriste bicikl duže od 15 minuta, udio djece koja u školu idu pješice ili biciklom, komunikacijsku koheziju, stupanj u kojem su kulturni resursi zastupljeni u planiranju. Opcijski ekološki pokazatelji su kvaliteta življenja, zagađenje vode, očuvanje staništa, korištenje održivih izvora energije i energetska učinkovitost popratnih objekata u prometnom sustavu.

Marletto i Mameli [44] izbor pokazatelja definiraju trima grupama ciljeva, koji ukupno sadrže devet podciljeva. Grupe su: društveno održiv grad (alternativa mobilnosti, lakoća kretanja, dostupnost javnih površina, buka, čist zrak i sigurnost), ekološki održiv grad (smanjenje stakleničkih plinova, smanjenje zauzeća zemljišta) i ekonomski održiv grad (smanjenje troškova mobilnosti). Krajnji rezultat je skup od 14 pokazatelja (javne i privatne

usluge dostupne putem telefona ili računala, zagušenja, pokazatelj pješačkog prometa, pokazatelj biciklističkog prometa, kvaliteta i kvantiteta JGPP-a, broj motoriziranih vozila po km², gustoća prijeđenog puta po km², zatim udio populacije izložene većoj emisiji buke od dozvoljenog, emisije štetnih plinova, stradali i ozlijeđeni u prometu, emisije CO₂ iz prometa, zauzeće zemljišta od strane prometne infrastrukture, otpad generiranim prometnim aktivnostima, prosječni troškovi kućanstava, kompanija i gradske uprave vezane za mobilnost).

Toth-Szabo sa suradnicima [45] se bavi definiranjem okvira za razradu pokazatelja mobilnosti. Pokazatelji se prvo u najširem kontekstu grupiraju u tri kategorije (gospodarstvo, društvo, ekologija). Gospodarstvo uključuje učinkovitost (udio zadovoljstva tvrtki i javnih ustanova prometnim sustavom, godišnje investicije u teretni i putnički prijevoz) te dostupnost (zadovoljstvo prometnim sustavom krajnjih korisnika za putovanje na posao i za ostala putovanja). U grupi društvo definirana je dostupnost (udio dostupnih poslova i usluga u krugu od 45 minuta putovanja, modalna razdioba), zatim sigurnost (udio populacije koji se osjeća sigurno u prometu, rizik ozljede po osobi kilometru) te življenje (udio korisnika koji se osjeća sigurno u odnosu na prometne prekršaje, zadovoljstvo javnim površinama koje su vezane za transport, broj prometnih nezgoda ili incidenata u prometnom sustavu po osobi kilometru, udio djece koja u školu ne idu automobilom). U grupi ekologija postoje dvije podgrupe i to emisije (udio stanovništva koje nije zadovoljno stanjem emisija i buke iz prometnog sustava, godišnji troškovi za pojedinca ili društvo uzrokovani emisijama), odnosno resursi (udio populacije koja misli da je zauzeće zemljišta za potrebe prometa odgovarajuće, zauzeće zemljišta za potrebe prometa, udio stanovništva koje misli da su održivi izvori energije pristupačni, udio obnovljive energije u ukupnoj energiji koju konzumira prometni sustav).

Za potrebe procjene urbane mobilnosti u gradu Lyonu [46] definiran je skup pokazatelja s ciljem da bude relevantan, jednostavan i povezan s postojećom statističkom bazom. Pokazatelji su grupirani u četiri skupine te su vezani za mobilnost, ekonomiju, društvo i okoliš. Pokazatelji mobilnosti su broj putovanja, vrijeme putovanja, svrha putovanja, modalna razdioba, udaljenosti motoriziranih i nemotoriziranih putovanja te brzina. Ekonomski pokazatelji su godišnje investicije u infrastrukturu, cijene parkiranja, prirez, cijena parkiranja za zaposlenike i rashodi kućanstva. Društveni pokazatelji su prihodi kućanstva po jedinici potrošnje, stupanj motorizacije, trošak javnog gradskog prijevoza, troškovi goriva, cijena dnevne parkirališne karte, trošak parkiranja za rezidente te fiksni troškovi automobila alocirani na urbanu mobilnost. Ekološki pokazatelji su utrošak energije i emisija polutanata, zauzeće

javnih površina za potrebe putovanja, za potrebe parkiranja i prostor koji zauzima prometna infrastruktura.

Za potrebe projekta Sustainable Mobility Project 2.0 [27] autori su definirali skup pokazatelja kojima se procjenjuje urbana mobilnost. Cilj definiranih pokazatelja jest evaluirati mobilnosti u gradovima. Pokazatelji su podijeljeni u četiri grupe i to: globalno okruženje, kvaliteta života, ekonomska uspješnost i performanse sustava mobilnosti. Određen je skup od 19 pokazatelja i to: dostupnost JGPP-a siromašnim korisnicima, dostupnost osobama s posebnim potrebama, emisije štetnih plinova, zagađenje bukom, smrtnost, pristup uslugama mobilnosti, kvaliteta javne površine, urbana funkcionalna raznolikost, vrijeme putovanja u dnevnim migracijama, ekonomske okolnosti, neto javne financije, zauzeće prostora za mobilnost, emisije stakleničkih plinova, zagušenja i kašnjenja, energentska učinkovitost, mogućnosti za aktivnu mobilnost, intermodalna integracija, udobnost i zadovoljstvo te sigurnost. Svaki pokazatelj ocjenjuje se na skali od 0 do 10, a zbroj rezultata daje rezultantu vrijednosti za promatrani grad. Podaci se pribavljaju korištenjem jedne od pet definiranih metoda i to: anketa, mjerenja na terenu, korištenje postojećih podataka, geoprostorna analiza i modeliranje. Definiran je i skup dodatnih pokazatelja koji uključuju: stupanj motorizacije (2 ili 4 kotača), penetraciju mobilnih telefona, modalnu razdiobu, broj vozila kilometara po stanovniku, brzinu u prometnoj mreži, raspoloživost javnog gradskog prometa i atraktivnost centra grada za pristup osobnim automobilom.

Cianfano sa suradnicima [47] za potrebe procjene mobilnosti definira sljedeće pokazatelje: prosječna brzina na mreži, pokazatelj brzine na mreži, prosječna brzina vozila, pokazatelj brzine vozila, pokazatelj vremena boravka na mreži, pokazatelj kašnjenja na mreži, prosječno vrijeme putovanja, prosječna gustoća emisije polutanta iz prometa, prosječna izloženost polutantima iz prometa, prosječna izloženost polutantima iz svih izvora, prosječna vremenska izloženost polutantima, ukupna emisija polutanata.

Norwood sa suradnicima [28] mobilnost određuje s nekoliko ključnih pokazatelja koje svaka procjena mobilnosti mora obuhvatiti. Riječ je o vremenu putovanja, izgubljenom vremenu (ili percepciji izgubljenog vremena), pouzdanosti sustava (ili stupnju nepredviđenih zahtjeva), stanju prometnog sustava i troškovima putovanja. Opcijske pokazatelje mobilnosti svrstavaju u šest grupa i to one vezane za zagušenja (razina usluge, količina prometa, kapacitet prometnice, zastoji), zatim vrijeme putovanja, količina putovanja vozilo kilometri i vozilo sati putovanja), modalna razdioba, vrijeme potrebno za tranzit i učinkovitost tranzita.

Irman i Low [48] su predložili skup pokazatelja koji su grupirani u sljedeće kategorije: okoliš, društvo, ekonomija i promet. Pokazatelji vezani za transport odnose se na nemotorizirani promet, vlasništvo automobila, prosječno vrijeme putovanja, količinu prometa i stanje vozila. Društveni pokazatelji odnose se na urbanu gustoću, zauzeće prostora, dostupnost javnog gradskog prometa, stanje poginulih i ozlijeđenih u prometu. Ekonomski pokazatelji vezani su za cijenu goriva, BDP po glavi stanovnika, zauzeće površine u smislu transportne infrastrukture. Ekološka mjerila su ona u smislu emisije stakleničkih plinova, emisije CO₂ i CH₄, NO₂ i buke.

Barker sa suradnicima [49] analizira održivost prometnog sustava i mobilnost u gradu San Antonio u SAD-u. Definirani su pokazatelji u smislu vremena putovanja, odnosno zagušenosti, zatim troškova generiranih transportom, stradalima u prometu, potrošnjom energije i emisijom polutanata. Ključni pokazatelj jest broj vozilo kilometara.

Costa i suradnici [29] definiraju skup mjerila za praćenje održive urbane mobilnosti u gradovima. Proces odabira pokazatelja uključuje nekoliko faza, od kojih je u prvoj identificirano 465 pokazatelja mobilnost. U drugoj fazi uslijedila je kategorizacija i grupiranje, što je rezultiralo listom suženom na 115 pokazatelja. Organizirani su u kategorije i teme. Kategorije su transport i okoliš (energija i gorivo, utjecaj na okoliš, kvaliteta zraka i buka), upravljanje urbanom mobilnošću (strategije/investicije, upravljanje, strategija za unapređenje urbane mobilnosti, nove tehnologije), infrastruktura i transportna tehnologija (infrastrukture/sustav prometnica, tehnologija i usluge u transportu, promet), prostorno planiranje i prometni zahtjevi (pristup urbanom području, urbani razvoj, urbano izmještanje) te društveno-ekonomski aspekti transporta (društveno-ekonomski aspekti transporta, sigurnost, tranzit). Končana lista svedena je na 24 pokazatelja i to na fragmentaciju zemljišta, utjecaj korištenja automobila, otpad koji generira automobil, broj dana u kojem su polutanti u zraku iznad dozvoljene granice, emisije štetnih plinova iz transporta, emisije stakleničkih plinova u ovisnosti o modu, intenziteti emisija generiranih transportom, stanovništvo izloženo emisijama iz transporta, zagađenje bukom, investicije u transportni sustav, upravljanje prometom, nacionalni prometni i ekološki sustav nadzora, plan redukcije putovanja, dostupnost gradskog centra, dostupnost osnovnih usluga i trgovina prijevoznim sredstvima, pristup prometnim uslugama, urbano planiranje, gustoća stanovništva, stopa rasta stanovništva, lokalna mobilnost i prijevoz putnika, smrtnost u prometnim nezgodama, sigurnost rezidencijalnih područja.

U sklopu projekta Conduits [22], [35], autori Kaparis i Bell definirali su skup pokazatelja koji su namijenjeni upravljanju prometom i inteligentnim transportnim sustavima. Unutar grupe pokazatelja pod nazivom „prometna učinkovitost“ obrađuje se područje mobilnosti koje je definirano s 14 pokazatelja. Oni su: prosječno vrijeme putovanja cestovnom mrežom do odgovarajuće točke interesa, prosječno vrijeme putovanja JGPP-om do odgovarajuće točke interesa, kapacitet/ponuda javnog gradskog prometa, vrijeme potrebno za prijelaz među prometnim sredstvima, prosječna udaljenost između modova transporta, vrijeme pristupa do kolodvora, prosječno vrijeme potražnje za parkirališnim mjestom, prosječno trajanje dnevnih putovanja, prosječna udaljenost dnevnih putovanja, ukupna dužina cestovne mreže, pokrivenost cestovne mreže uslugama ITS-a, modalna razdioba, udio nemotoriziranih putovanja u dnevnim migracijama te dužina mreže za nemotorizirana putovanja.

EYGM [50] definira urbane pokazatelje mobilnosti kao skup okvirnih parametara koji mogu pomoći gradskoj administraciji u proaktivnoj interakciji s dionicima u ekosustavu mobilnosti. Okvir se sastoji od tri grupe pokazatelja i to su gradski strukturni čimbenici, infrastruktura i demografija. Gradski strukturni pokazatelji obuhvaćaju prostornu komponentu (zelenilo, povezivost, zagađenje), upravu i financije (struktura, financije, učinkovitost) i prometnu politiku (transport, inovacije). Infrastruktura uključuje infrastrukturnu mrežu i njenu kvalitetu (modalna razdioba, povezivost intermodalnog prometa, gustoća mreže, kvaliteta cestovne mreže, zagušenje, parkirališta i kvaliteta JGPP-a, zatim balans ponude i potražnje za mobilnošću - prosječno vrijeme putovanja, uzorak korištenja, modalna razdioba) i IT infrastrukturu u podršci mobilnosti (ITS, pametne komunalne službe). Demografija uključuje razdiobu po dobi, edukaciji, ekonomskom statusu, vlasništvu vozila, posjedovanju vozačke dozvole i povezivosti.

Stantchev i Rye [51] su tijekom projekta Civitas u sklopu alata za integralno planiranje mobilnosti definirali šest grupa ključnih pokazatelja osobne mobilnosti koji su vezani za javni prijevoz (usluga JGPP-a po glavi stanovnika, cijena JGPP-a, udaljenost od kuće do najbliže stanice javnog prijevoza), dostupnost (dostupnost van urbanog prostora, dostupnost ključnih usluga, gustoća - zauzeće zemljišta), aktivno putovanje (šetnice van cesta, biciklističke staze, ulice sa smirenim prometom ili bez prometa, pogodne za pješake i bicikliste) parkiranje i dijeljenje automobila i bicikala (zauzeće zemljišta za parkiranje, cijena parkiranja, broj automobila i stanica u sustavu dijeljenja automobila po glavi stanovnika, broj bicikala i stanica u sustavu dijeljenja bicikala po glavi stanovnika), rezultati (modalna razdioba, ukupna

udaljenost i vrijeme putovanja po modovima transporta, zadovoljstvo korisnika transportnim sustavom, usporedba brzine kretanja vozila JGPP-a i osobnih automobila u vršnim razdobljima, pouzdanost JGPP-a, udio vlasništva osobnih automobila, udio vlasništva bicikala) te utjecaji (emisija CO₂ iz osobnog transporta po glavi), emisije PM₁₀, emisije NO, buka, zdravlje - fizička aktivnost, aktivnosti vezane za trgovinu te sigurnost u smislu poginulih i ozlijeđenih osoba u prometu).

2.5.3. Pregled pokazatelja po kategorijama

Pokazatelje mobilnosti navedene u prethodnom potpoglavlju i dostupne u literaturi možemo grupirati po domenama kojima pripadaju. Pokazatelje mobilnost stoga se može organizirati u skupine transportnih pokazatelja, ekonomskih pokazatelja, okolišnih pokazatelja, društvenih pokazatelja i ostalih pokazatelja. Transportni pokazatelji prikazuju mobilnost kroz kategorije koje su vezane za transportni aspekt i pokazuju utjecaj tih komponenti na mobilnost. Transportni pokazatelji s pripadajućim mjernim jedinicama su prikazani u tablici 2.

Tablica 2. Pregled transportnih pokazatelja

Transportni pokazatelji	Jedinica	Transportni pokazatelji	Jedinica
Prosječna udaljenost dnevnih putovanja	km	Količina putovanja	vozilo/sati
Prosječno dnevno vrijeme putovanja po osobi	h	Broj putovanja	broj
Prosječno vrijeme putovanja po kilometru	h	Vrijeme putovanja	h
Prosječno vrijeme putovanja po vozilu	h	Svrha putovanja	%
Ukupan broj putničkih i tonskih kilometara	pkm/tkm	Prosječno vrijeme putovanja JGPP do odgovarajuće točke interesa	h
Faktor pouzdanosti	0-1	Kapacitet/ponuda javnog gradskog prometa	broj pmj
Prosječno vrijeme putovanja cestovnom mrežom do odgovarajuće točke interesa	h	Vrijeme potrebno za prijelaz među prometnim sredstvima	h
Prosječna brzina kretanja vozila	km/h	Prosječna udaljenost između modova transporta	km
Prosječna brzina kretanja teretnog prometa	km/h	Vrijeme pristupa do kolodvora	h
Dužina cestovne mreže	km	Usluge JGPP-a po stanovniku	putovanja/st
Dužina mreže za nemotorizirana putovanja	km	Modal Split (načinska raspodjela putovanja)	%
Pokrivenost cestovne mreže uslugama ITS	%	Prosječno vrijeme potražnje za parkirališnim mjestom	h
Količina prometa (izražena u jedinici „prosječna automobilska jedinica“)	PAJ	Zagušenja u prometnom sustavu	h
Kapacitet prometnice	vozila/h	Kašnjenja u prometnom sustavu	h
Količina putovanja vozilo/kilometri	vozilo/km		

Izvor: [22], [27]–[29], [35], [46]–[48]

Ekonomski pokazatelji prikazuju mobilnost kroz kategorije koje su vezane za ekonomski aspekt i pokazuju utjecaj pojedinih ekonomskih komponenti na mobilnost.

Društveni pokazatelji prikazuju mobilnost kroz njezinu društvenu prihvatljivost. Ekonomski i društveni pokazatelji s pripadajućim mjernim jedinicama su prikazani u tablici 3 i 4.

Tablica 3. Pregled ekonomskih pokazatelja

Ekonomski pokazatelji	Jedinica
Cijena karte javnog gradskog prijevoza	kn
Cijena litre goriva	kn
Cijena dnevne parkirališne karte	kn
Cijena parkiranja za rezidente	kn
Cijena parkiranja za zaposlenike tvrtki	kn
Cijena korištenja sustava javnih bicikala	kn
Cijena korištenja sustava javnih automobila	kn
Fiksni troškovi automobila (alocirani na urbanu mobilnost)	kn
Troškovi zagađenja po stanovniku	kn
Ukupna davanja na transport po stanovniku	kn
Broj javnih usluga i prilika za posao u dosegu od 10 minuta pješaćenjem ili 20 minuta putovanja	broj
Ukupni rashodi kućanstva	kn
Prihodi kućanstva po jedinici potrošnje	kn
Prosječni rashodi kućanstava, kompanija i gradske uprave vezanih za mobilnost	kn
Udio zadovoljstva tvrtki i javnih ustanova financijskim aspektom sustava mobilnosti	%
Godišnje investicije u teretni i putnički prijevoz	kn
Godišnje investicije u infrastrukturu	kn
Ukupni troškovi generirani transportom	kn
BDP	kn

Izvor: [19], [27], [34], [45], [46], [48]

Tablica 4. Pregled društvenih pokazatelja

Društveni pokazatelji	Jedinica
Broj nesreća	broj
Broj ozlijeđenih osoba	broj
Broj smrtno stradalih	broj
Prilagođenost prometnog sustava karakterističnim skupinama korisnika	%
Opće zadovoljstvo prometnim sustavom	%
Prilagođenost osobama s posebnim potrebama	%
Udio osoba koji dnevno šecu ili koriste bicikl duže od 15 minuta	%
Udio djece koja u školu idu pješice ili biciklom	%
Komunikacijska kohezija	%
Percepcija sigurnosti	%
Udio korisnika koji se osjećaju sigurno u odnosu na prometne prekršaje	%
Zadovoljstvo javnim površinama koje su vezane za transport	%
Pristup uslugama mobilnosti	%
Broj prometnih nesreća u prometnom sustavu po stanovniku/kilometru	br/st/km

Izvor: [19], [27], [34], [45], [46], [48]

Okolišni pokazatelji prikazuju mobilnost kroz kategorije koje su vezane za okoliš, meteorološke uvjete, itd. Ostali pokazatelji su oni koje nije moguće svrstati niti u jednu od prethodno navedenih kategorija (npr. postojanje regulatornih okvira, tijela za upravljanje ili planiranje mobilnošću, urbanizam, demografija, itd.). Okolišni i ostali pokazatelji s pripadajućim mjernim jedinicama su prikazani u tablicama 5 i 6.

Tablica 5. Pregled okolišnih pokazatelja

Pokazatelji vezani za okoliš	Jedinica	Pokazatelji vezani za okoliš	Jedinica
Buka	dB	Otpad generiran prometnim aktivnostima	t
Emisije stakleničkih plinova	g/km	Zauzeće zemljišta za potrebe prometa po stanovniku	%
Emisije polutanata	g/km	Zauzeće javnih površina za potrebe putovanja	%
Potrošnja energije	kWh	Zauzeće javnih površina za potrebe parkiranja	%
Korištenje održivih izvora energije	%	Zauzeće javnih površina za prometnu infrastrukturu	%
Udio obnovljive energije u ukupnoj energiji koju konzumira prometni sustav	%	Fragmentacija zemljišta	%
Utrošak energije po stanovniku po modu prometa	kWh	Prosječna izloženost polutantima iz prometa	%
Potrošnja energije po tonskom kilometru	kWh/tkm	Prosječna izloženost polutantima iz svih izvora	%
Broj dana u kojem su polutanti u zraku iznad dozvoljene granice	br. dana	Utjecaj korištenja automobila	ocjena (1-5)
Ekološke investicije	kn	Prosječna vremenska izloženost polutantima	h
Udio populacije koja nije zadovoljna stanjem emisija i buke iz prometnog sustava	%	Meteorološki uvjeti	ocjena (1-5)
Udio populacije čiji je stav da je zauzeće zemljišta za potrebe prometa odgovarajuće	%	Energetska učinkovitost popratnih objekata u prometnom sustavu	ocjena (1-5)
Udio populacije čiji je stav da su održivi izvori energije pristupačni	%		

Izvor: [19], [22], [27]–[29], [34], [35], [44]–[48]

Tablica 6. Pregled ostalih pokazatelja

Ostali pokazatelji	Jedinica
Stopa motorizacije (2 ili 4 kotača)	br. voz/1000 st
Penetracija mobilnih telefona	%
Alternativa mobilnosti	ocjena (1-5)
Lakoća kretanja	ocjena (1-5)
Javne i privatne usluge dostupne putem telefona ili računala	ocjena (1-5)
Broj motoriziranih vozila po km ²	vozilo/km ²
Gustoća prijeđenog puta po km ²	broj/km ²
Sustav upravljanja prometom	DA/NE
Ekološki sustav nadzora	DA/NE
Plan redukcije putovanja	DA/NE
Dostupnost gradskog centra	ocjena (1-5)
Dostupnost osnovnih usluga i trgovina prijevoznim sredstvima	ocjena (1-5)
Urbano planiranje	DA/NE
Dob	god
Edukacija	ocjena (1-5)
Ekonomski status	ocjena (1-5)
Vlasništvo vozila	%
Posjedovanje vozačke dozvole	%

Izvor: [19], [22], [27]–[29], [34], [35], [44]–[48]

Sljedeći korak u procjeni urbane mobilnosti jest uspostava indeksa urbane mobilnosti na temelju podataka i pokazatelja urbane mobilnosti.

2.6. Indeksi urbane mobilnosti

2.6.1. Općenito o indeksima urbane mobilnosti

Indeks urbane mobilnosti može se definirati kao rezultat fuzije odnosnih podataka i/ili pokazatelja mobilnosti s ciljem dobivanja procjene mobilnosti. Indeksi se koriste za smanjivanje stupnja složenosti i opsega podataka i pokazatelja koje je potrebno uključiti u procjenu urbane mobilnosti. Prednosti korištenja indeksa su te da mogu svesti značajnu količinu informacija različite prirode na jedan skalar, da se koriste za ocjenu stanja kompleksnih sustava u cjelini, a ne na razini pojedinih komponenti, a indekse dobivene istom metodologijom moguće je uspoređivati. Korištenje indeksa ima i nedostatke. Obzirom da je riječ o jedinstvenom broju, indeks ne daje neposredni uvid u elemente koji se mijenjaju, odnosno može biti različito otporan na promjene pojedinih komponenti. Indeks može maskirati pravu informaciju, a robusnost može biti ograničena različitim prostornim i vremenskim faktorima [43].

2.6.2. Postojeći indeksi urbane mobilnosti u literaturi

U znanstvenoj literaturi je zabilježeno nekoliko indeksa mobilnosti, koji mobilnosti iskazuju putem jedinstvenog broja generiranog odgovarajućim matematičkim modelom iz podataka, pokazatelja ili drugih indeksa.

Prvi značajno rasprostranjen indeks urbane mobilnosti definirao je Frei i on nosi naziv „uzorkovani indeks mobilnosti“ (engl. *sampling mobility index* – *SMI*) [23]. Uzorkovani indeks mobilnosti prikazan je relacijom (1). Frei je uspostavio skup pokazatelja i indeksa namijenjenih mjerenju stupnja mobilnosti u malim i srednjim urbanim okružjima. Pokazatelje mobilnosti definirao je kroz slijedeće kriterije: širina nogostupa, mogućnost prolaska pješaka, vertikalna i horizontalna signalizacija, korištenje sigurnosnih pojaseva, poštivanje svjetlosne signalizacije, postojanje svjetlosne signalizacije za pješake, dostupnost biciklističkih staza, te broj osoba u vozilu. Za svaki od kriterija definirao je pokazatelje, koje potom objedinjuje u sedam indeksa, po jedan za svaki kriterij. Na taj način različite veličine normalizira, odnosno sve kriterije svodi na jednu dimenziju. Tih sedam indeksa objedinjuje u jedan integrirani indeks koji je nazvan „uzorkovani indeks mobilnosti“. Podaci koji se koriste za izračun dobiveni su analizom na terenu ili putem ankete. Indeks predstavlja sumu vrijednosti sedam uključenih indeksa:

$$SMI = \sum (SWI + FWPI + VHSI + SBUI + RTLI + PTLI + MOPVI + IC) \quad (1)$$

pri čemu je:

- SWI indeks širine nogostupa,
- FWPI indeks mogućnosti prolaska pješaka,
- VHSI indeks vertikalne i horizontalne signalizacije,
- SBUI indeks korištenja sigurnosnih pojaseva,
- RTLI indeks poštivanja svjetlosne signalizacije,
- PTLI indeks postojanja svjetlosne signalizacije za pješake,
- MOPVI indeks broja osoba u vozilu i
- IC indeks dostupnosti biciklističkih staza.

Najveća vrijednost koju ovaj indeks može sadržavati jest 700 bodova, a najniža nula. Ukupan raspon podijeljen je u pet kategorija, pri čemu ona od 0 do 140 označava najgori rezultat (crveno), a ona od 560 do 700 bodova najbolji rezultat (zeleno) [43].

Indeks mobilnost „Travel Time Index – TTI“ (2), autori su identificirali kao indeks vremena putovanja [52]. Koristi se za mjerenje razlika u zagušenju u prometu među metropolitanskim područjima, odnosno vezan je za brzinu prometnog toka. Indeks vremena putovanja računa se kao količnik vremena potrebnog za putovanje tijekom zagušenja i vremena potrebnog za prolazak iste dionice u razdoblju bez zagušenja.

$$TTI = \frac{Vrijeme_putovanja_za_vrijeme_zagušenja_ (engl._CongestedTravelTime)}{Vrijeme_putovanja_bez_zagušenja_ (engl._FreeFlowTravelTime)} \quad (2)$$

Shared Mobility City indeks je primjer indeksa koji nastaje zbirom ocjena (vrijednosti rezultata) 11 pokazatelja koji u tri kategorije (opći podaci i demografija, mobilnost, vizija i ciljevi) ocjenjuju mobilnost. Ovaj indeks namijenjen je donosiocima odluka na razini gradskih uprava kada je u pitanju uvođenje nekih usluga povezanih s mobilnošću. Indeks pruža uvid u potrebe i spremnost određene sredine za implementacijom sustava javnih vozila (sustav javnih automobila) [53].

Indeks urbane mobilnosti, razvijen na sveučilištu Imperial College iz Londona za potrebe projekta Conduits, predstavlja veličinu koja označava status mobilnosti unutar inteligentnog transportnog sustava, a koji se izračunava matematičkim modelom (3) [22].

$$I_{mob} = W_{PV} \cdot \frac{1}{|R_{PV}|} \sum_{r \in R_{PV}} \frac{ATT_{PV}^r}{D_r} + W_{PT} \cdot \frac{1}{|R_{PT}|} \sum_{r \in R_{PT}} \frac{ATT_{PT}^r}{D_r} \quad (3)$$

gdje je:

- I_{mob} indeks mobilnosti,
- r ruta (matrica putovanja) između izabranih R_{pv} (ruta osobnih putovanja) i R_{PT} (ruta JGPP-a),
- ATT_{pv}^r prosječno vrijeme putovanja za rutu r osobnim prijevoznim sredstvima,
- ATT_{pt}^r prosječno vrijeme putovanja za rutu R JGPP-om,

- D_r označava dužinu rute r ,
- W_{pv} predstavlja težinske faktore za vrijeme putovanja osobnim sredstvima putovanja i
- W_{pt} predstavlja težinske faktore za vrijeme putovanja JGPP-om.

Težinski faktori određuju se Delfi metodom [46]. U prvom krugu Delfi metode prikuplja se procjena relativne važnosti pojedinih pokazatelja, ocjenjivanjem svakog pojedinačno. Svaki ekspert pokazatelju pridodaje vrijednost u rasponu od 0 do 1. U drugom krugu se prikupljaju informacije o odnosima pojedinih pokazatelja koji čine indeks te se verificiraju odgovori iz prvog kruga. Konačan rezultat su težinski faktori u rasponu od 0 do 1 koji se potom uključuju u model. Indeks mobilnosti I_{mob} izražava se u veličini vrijeme putovanja po kilometru.

Autori su indeks unaprijedili na način da je u model uključen i faktor važnosti dionice (rute), kako je prikazano u jednadžbi (4) [35]:

$$I_{mob} = W_{PV} \cdot \frac{1}{|R_{PV}|} * w_r * \sum_{r \in R_{PV}} \frac{ATT_{PV}^r}{D_r} + W_{PT} \cdot \frac{1}{|R_{PT}|} * w_r * \sum_{r \in R_{PT}} \frac{ATT_{PT}^r}{D_r} \quad (4)$$

gdje je:

- I_{mob} indeks mobilnosti,
- r ruta (matrica putovanja) između izabranih R_{pv} (ruta osobnih putovanja) i R_{pt} (ruta JGPP-om),
- ATT_{pv}^r prosječno vrijeme putovanja za rutu r osobnim prijevoznim sredstvima,
- ATT_{pt}^r prosječno vrijeme putovanja za rutu r JGPP-om,
- D_r označava dužinu rute r ,
- W_{pv} predstavlja težinske faktore za vrijeme putovanja osobnim sredstvima putovanja,
- W_{pt} predstavlja težinske faktore za vrijeme putovanja JGPP-om i
- W_r predstavlja težinski faktor za odgovarajuću rutu.

U odnosu na prethodnu iteraciju, novi element je težinski faktor za odgovarajuću rutu (W_r) koji se također izračunava Delfi metodom, a ostali elementi i metodologija se nisu mijenjali.

Zaključak je da ne postoji općeprihvaćeni indeks za procjenu urbane mobilnosti. Postojeći pokazatelji i indeksi urbane mobilnosti uglavnom su ciljano razvijani za određene gradove ili urbana područja, uzimajući u obzir lokalne specifičnosti, tako da je njihova primjena ograničena samo na to područje. Bez obzira na veliki broj definiranih pokazatelja mobilnosti, za formiranje indeksa urbane mobilnosti uglavnom se koristi njihov ograničeni broj. Također, izbor pokazatelja urbane mobilnosti uglavnom je vezan za dostupnost podataka, odnosno postojanje određenog izvora podataka, što ograničava objektivno i usporedivo ocjenjivanje mobilnosti stanovnika urbanih aglomeracija u kojima takvi podaci, odnosno izvori, ne postoje. Također, za procjenu urbane mobilnosti se uglavnom koriste konvencionalni izvori podataka, a potencijal „novih“ izvora podataka nije dovoljno iskorišten.

2.7. Odnos urbane mobilnosti i razina usluge

Postoji nekoliko načina definiranja procjene mobilnosti, a jedan od njih je i opisivanje kroz razinu usluge (engl. *Level of Service* – LoS) pojedinih modova prometa koji sudjeluju u mobilnosti [19]. Razina usluge je mjera koja se koristi za opisivanje kvalitete prometne usluge (engl. *Quality of Service* – QoS). Kvaliteta prometne usluge opisuje koliko dobro prometni sustav operativno djeluje iz perspektive krajnjeg korisnika. Razine usluga definiraju se putem jedinstvenog skupa pravila i odgovarajućih pokazatelja koji se koriste za opisivanje operativnih uvjeta u prometnom sustavu. Promjena u razini usluge pokazuje da su vrijednosti pokazatelja prometnog sustava tranzitirale iz jednog određenog raspona vrijednost u drugi, a ukoliko je razina usluge ostala nepromijenjena, to pokazuje da se vrijednosti pokazatelja prometnog sustava nisu mijenjale ili da su ostale unutar istih raspona. Razina usluge predstavlja ocjenu kroz kvantitativno raslojavanje kvalitete usluge. Kvaliteta prometne usluge se ocjenjuje korištenjem pokazatelja koji su mjerljivi iz perspektive krajnjeg korisnika (npr. kašnjenje, cijena) ili korištenjem pokazatelja koje je moguće izmjeriti na razini infrastrukture ili cjelokupnog prometnog sustava (srednja brzina vozila JGPP-a, broj vozila na prometnici i slično).

Općenito, definirano je šest razina usluga, od razine A do razine F [54]. Razina A predstavlja najbolju (najvišu) razinu prometne usluge, dok razina F predstavlja najgoru (najnižu) razinu prometne usluge. Svrha određivanja razine kvalitete prometnih usluga kroz ovakvu skalu ocjenjivanja jest pojednostavniti prikaz složenih numeričkih rezultata performansi prometnog sustava kroz jedinstven sustav ocjenjivanja. Krajnji cilj jest

pojednostavljenje percepcije ocjenjivanja prometnog sustava, čime takav način ocjenjivanja postaje lako razumljiv domenskim stručnjacima i krajnjim korisnicima. U prometnom inženjerstvu su općeprihvaćene razine usluge definirane u publikaciji *Highway Capacity Manual* (HCM) [54]. Prema HCM-u, moguće je definirati razinu usluge kao kvalitativnu mjeru koja se sastoji od više pokazatelja. HCM predviđa korištenje proširene liste pokazatelja, odnosno reducirane liste pokazatelja.

Proširen broj pokazatelja uključuje:

- vrijeme putovanja, brzinu i kašnjenja,
- broj zaustavljanja,
- pouzdanost trajanja putovanja (odstupanja u trajanju putovanja istim prijevoznim sredstvom na istoj dionici),
- slobodu manevriranja (promjena vozne trake, udio u vremenu koji se odnosi na praćenje drugih vozila, mogućnost izbora pješačke ili biciklističke rute),
- udobnost u prometu (interakcija pješaka i biciklista, njihova odvojenost od ostalih vidova prometa, udobnost korištenja javnog gradskog prijevoza putnika, udobnost vožnje uopćeno),
- praktičnost (mogućnost izravnog putovanja, potrebe za mijenjanjem prijevoznog sredstva, povezanost različitih prijevoznih sredstava),
- sigurnost (stvarna i percipirana),
- troškovi putovanja,
- dostupnost sadržaja i usluga i
- dostupnost informacija.

Broj navedenih pokazatelja, prema HCM-u, moguće je reducirati i prilagoditi, tako da uobičajeno procjena razine prometne usluge obuhvaća sljedeće pokazatelje:

- karakteristika prometnog toka,
- sloboda manevriranja,
- brzina kretanja,
- sloboda kretanja i
- vremena čekanja.

Kriteriji za definiranje pojedinih razina usluga posebno su definirani za pojedini način prijevoza, kao što su javni gradski prijevoz putnika, pješački, biciklistički promet, prijevoz osobnim automobilom, itd. Također, razina usluge može varirati i u ovisnosti o vrsti i kontekstu prometnice, radi li se o urbanoj ili ruralnoj prometnici, o kategoriji ceste, vrsti raskrižja, vrsti signalizacije na raskrižju i slično.

Definirano je šest razina usluga:

Razina usluge A - uvjeti potpuno slobodnog toka, odgovarajuće gustoće prometa i pune slobode manevriranje. Sudionici u prometu mogu birati brzinu kretanja. Prisutni su minimalni međusobni utjecaji (do 10 %), prosječna vremena čekanja su minimalna. Individualna sloboda kretanja nije narušena. Uvjeti kretanja su ograničeni samo kapacitetom infrastrukture [54]. Za razinu uslužnosti osiguran je dovoljan prostor po pješaku da pješaci mogu slobodno izabrati brzinu kojom će se kretati. Također mogu obilaziti sporije pješake i izbjegavati konflikte s pješacima koji se kreću poprečno u odnosu na smjer njihovog kretanja [55]. Razina usluge A javlja se uglavnom noću u urbanim uvjetima, a često se javlja tijekom dana u ruralnim uvjetima.

Razina usluge B - uvjeti slobodnog prometnog toka, stabilni prometni tok s minimalno ograničenim brzinama kretanja kao posljedicom gustoće toka. Prosječna vremena čekanja nisu značajna. Individualna sloboda kretanja je u maloj mjeri narušena. Najmanje 70 % vozila nalazi se u uvjetima slobodnog toka [54]. Kada na pješačkoj prometnici postoji razina uslužnosti B na raspolaganju je dovoljan prostor po pješaku za kretanje normalnom brzinom i prestizanje drugih pješaka u jednosmjernom toku, u kretanju pješaka u suprotnom smjeru javljaju se manji konflikti [55]. U urbanim aglomeracijama uvjeti razine usluge B vladaju tijekom kasnih večernjih ili ranih jutarnjih sati.

Razina usluge C - stanje stabilnog prometnog toka, uz ograničenje slobode manevriranja i izbora brzine. Mogući su manji repovi čekanja, vremena čekanja su osjetna. Individualna sloboda kretanja je osjetno narušena. Najmanje 50 % vozila nalazi se u uvjetima slobodnog toka [54]. Ograničen je slobodan izbor individualne brzine kretanja pješaka i slobodno prestizanje drugih pješaka. Javlja se zahtjev za čestim prilagođavanjem brzine i smjera kretanja u cilju izbjegavanja kontakta, može se očekivati kontinuiran protok [55]. Za većinu urbanih prometnih sustava ovo je ciljano stanje razine usluge za vrijeme vršnih prometnih opterećenja. Međutim, uvjeti razine C u urbanim aglomeracijama uglavnom odgovaraju razdobljima između jutarnjeg i podnevnog vršnog opterećenja.

Razina usluge D – stanje prometnog toka koje se približava nestabilnom toku, velike gustoće s bitno ograničenim brzinama i malom mogućnošću manevriranja. Poveći repovi čekanja, veća prosječna vremena čekanja. Individualna sloboda kretanja je jasno narušena. Više od 40 % vozila nalazi se u uvjetima slobodnog toka [54]. Većina pješaka se mora kretati brzinom manjom od njihove normalne brzine zbog teškoća pri prestizanju sporijih pješaka i zbog izbjegavanja konflikata, pojava višestrukih konflikata s drugim pješacima [55]. Uvjeti razine D u urbanim aglomeracijama uglavnom odgovaraju razdoblju jutarnjeg vršnog opterećenja.

Razina usluge E – stanje nestabilnog prometnog toka s vožnjom u nizu, gdje je gustoća bliska zagušenju, a protok jednak propusnoj moći, pa su mogući povremeni zastoji. Čekanja su velika, propusna moć prometnice je dosegnuta. Individualna sloboda kretanja je gotovo stalno narušena i onemogućena [54]. Svi pješaci se moraju kretati brzinom manjom od svoje normalne brzine uz često potrebno prilagođavanje tempa kretanja. Raspoloživi prostor po pješaku je nedovoljan za prestizanje pješaka koji se sporije kreću, tj. javljaju se česti prekidi toka [55]. Uvjeti razine E u urbanim aglomeracijama uglavnom odgovaraju razdoblju popodnevno vršnog opterećenja.

Razina usluge F - usiljeni-prisilni prometni tok s brzinama koje su manje od kritičnih brzina. Gustoća je veća od kritične, a protok je u rasponu od nule do vrijednosti koja je manja od propusne moći. Prometna potražnja je iznad propusne moći, vremena čekanja su velika, utjecaj se širi i na okolnu prometnu mrežu. Individualna sloboda kretanja onemogućena je u potpunosti, prometni sustav je u potpunosti disfunkcionalan [54]. Sve brzine kretanja pješaka su ekstremno ograničene, javlja se čest kontakt s drugim pješacima, a kretanja u suprotnom smjeru su praktički nemoguća. Karakterizira situaciju čekanja u redu [55]. Najčešće se javlja kao posljedica incidenata na prometnici, odnosno u slučaju posebnih događanja koja uzrokuju potpuno zatvaranje prometnica.

Razine prometne usluge izravno su povezane i sa zadovoljstvom korisnika prometnog sustava [56]. Zadovoljstvo korisnika je definirano kao percepcija zadovoljstva korisnika o razini kojom su ispunjena njegova očekivanja [57]. Stupanj zadovoljstva korisnika predstavlja skalu kojom se vrednuje zadovoljstvo ili nezadovoljstvo korisnika kvalitetom usluge. Dokazana je veza između razine prometne usluge koje definira HCM sa zadovoljstvom korisnika prometnim sustavom [56]. Ukoliko se skala kojom se mjeri zadovoljstvo korisnika definira u rasponu od broja jedan do broja deset, pri čemu jedan predstavlja izrazito nezadovoljstvo

prometnim sustavom, a deset najveće zadovoljstvo prometnim sustavom, veza između razine usluge i zadovoljstva korisnika definira se kao u tablici 7. Numeričku skalu moguće je podijeliti u šest razreda koji opisuju šest razina zadovoljstva korisnika, a njima se potom pridjeljuju i opisne vrijednosti. Rezultat je prikaz razreda numeričkih vrijednosti u obliku Likertove skale [58]. Opisno, razina zadovoljstva tada se dijeli na korisnike koji su izrazito zadovoljni, zadovoljni, uglavnom zadovoljni, uglavnom nezadovoljni, nezadovoljni i izrazito nezadovoljni.

Tablica 7. Odnos razine usluge i zadovoljstva korisnika

Razina usluge	Zadovoljstvo korisnika	Opis razine zadovoljstva
Razina usluge A	>9,5	Izrazito zadovoljni
Razina usluge B	8,5-9,5	Zadovoljni
Razina usluge C	7,5-8,5	Uglavnom zadovoljni
Razina usluge D	5,0-7,5	Uglavnom nezadovoljni
Razina usluge E	4,0-5,0	Nezadovoljni
Razina usluge F	<4	Izrazito nezadovoljni

Shodno stajalištu da je mobilnost opisana razinom usluga pojedinih modova transporta [19], [34], može se definirati sljedeća kategorizacija mobilnosti, kao što je opisano u tablici 8.

Tablica 8. Odnos razine usluge i ocjene mobilnosti

Razina usluge	Ocjena mobilnosti
Razina usluge A	Izrazito visoka
Razina usluge B	Visoka
Razina usluge C	Viša-srednja
Razina usluge D	Niža- srednja
Razina usluge E	Niska
Razina usluge F	Izrazito niska



Slika 2. Pokazatelji kvalitete prometne usluge i razine mobilnosti

Slika 2. prikazuje odnos pokazatelja kvalitete usluge i razine mobilnosti. Sukladno navedenom u ovom poglavlju, stupnjeve mobilnosti je moguće definirati kako slijedi:

- kod „izrazito visoke mobilnosti“ u prometnom sustavu vladaju uvjeti potpuno slobodnog prometnog toka, s punom slobodom manevriranja, gdje sudionici

biraju brzinu kretanja, sloboda kretanja nije narušena, a vremena čekanja su minimalna. Korisnici su izrazito zadovoljni. **Primjer:** uvjeti koji vladaju uglavnom noću ili u prometnim sustavima sa znatno većim kapacitetima od prometne potražnje.

- kod „visoke mobilnosti“ u prometnom sustavu vladaju uvjeti slobodnog prometnog toka, sloboda manevriranja nije narušena, minimalno je ograničena brzina kretanja, sloboda kretanja je u maloj mjeri narušena, a vremena čekanja su rijetka i kratka. Korisnici su zadovoljni. **Primjer:** uvjeti koji u urbanim aglomeracijama vladaju tijekom kasnih večernjih ili ranih jutarnjih sati.
- kod „više srednje mobilnosti“ u prometnom sustavu vladaju uvjeti stabilnog prometnog toka, sloboda manevriranje je ograničena, ograničena je brzina kretanja, ograničena je sloboda kretanja i vremena čekanja su osjetna. Korisnici su uglavnom zadovoljni. **Primjer:** uvjeti koji u urbanim aglomeracijama odgovaraju razdobljima između jutarnjeg i podnevnog vršnog opterećenja.
- kod „niže srednje mobilnosti“ u prometnom sustavu vladaju uvjeti nestabilnog prometnog toka, s malom mogućnosti manevriranja, s bitno ograničenim brzinama, jasno narušenom slobodom kretanja i većim prosječnim vremenima čekanja. Korisnici su uglavnom nezadovoljni. **Primjer:** uvjeti koji u urbanim aglomeracijama odgovaraju razdoblju jutarnjeg vršnog opterećenja.
- kod „niske mobilnosti“ u prometnom sustavu vladaju uvjeti nestabilnog prometnog toka s kretanjem u nizu, sloboda manevriranja je gotovo stalno narušena, brzina kretanja je značajno ograničena i javljaju se zastoji, sloboda kretanja je gotovo stalno narušena, vremena čekanja su velika. Korisnici su nezadovoljni. **Primjer:** uvjeti koji u urbanim aglomeracijama odgovaraju vremenima popodnevnog vršnog opterećenja.
- kod „izrazito niske mobilnosti“ u prometnom sustavu vladaju uvjeti usiljenog-prisilnog prometnog toka, sloboda manevriranje je onemogućena u potpunosti, brzina kretanja je manja od kritičnih brzina, sloboda kretanja je onemogućena u potpunosti, vremena čekanja su izrazito velika. **Primjer:** uvjeti koji u urbanim aglomeracijama odgovaraju vremenima popodnevnog vršnog opterećenja.

2.8. Javne pokretne komunikacijske mreže i procjena mobilnosti

Prema definiciji, pokretna elektronička komunikacijska mreža obuhvaća prijenosne sustave i, prema potrebi, opremu za prispajanje ili usmjeravanje i druga sredstva koja omogućuju prijenos signala radijskim ili drugim elektromagnetskim sustavom bez obzira na vrstu podataka koji se prenose. Omogućava uspostavljanje elektroničke komunikacijske veze i u uvjetima fizičkog kretanja korisnika usluga te mreže i uspostavljanje telekomunikacijskih veza i u uvjetima fizičkog kretanja korisnika usluga te mreže [59].

U komercijalnoj primjeni koriste se javne pokretne komunikacijske mreže druge (GSM), treće (UMTS) i četvrte generacije (LTE), dok je peta generacija (5G) u fazi testiranja i normizacije.

2.8.1. Izvori podataka u pokretnim komunikacijskim mrežama

Unutar pokretnih komunikacijskih mreža, zbog prirode rada same mreže, prikupljaju se podaci koje je moguće koristiti za analize van telekomunikacijskog okružja i za druge namjene. Uobičajene namjene analitike tih (velikih) skupova podataka vezane su za marketing, javni sektor, maloprodaju, turizam, javnu sigurnost, ali i transport. Jedan od primjer korištenja tih podataka vezan je za definiranje pokazatelja za procjenu urbane mobilnosti.

Razlikujemo dva skupa podataka. Prvi skup podataka generiraju telekomunikacijski događaji koje iniciraju korisnici i nazivaju se podaci iz zapisa za naplatu telekomunikacijskih usluga (engl. *Call Data Records* – CDR), a drugi skup podataka generira mreža, a predstavlja signalizaciju (komunikaciju) između mrežnih elemenata u svrhu operativnog rada, optimizacije i održavanja same mreže (podaci o signalizaciji).

Prva grupa su podaci generirani (komunikacijskim) događajima i predstavljaju zapise koji se kreiraju po odvijanju neke telekomunikacijske aktivnosti u mreži. Događaji uključuju aktivnosti kao što su glasovni poziv, SMS ili MMS usluga, korištenje podatkovnog prometa te informacije o *roamingu*. Zapisi sadrže informaciju o vremenu početka aktivnosti i dužinu trajanja usluge, kao i vrstu aktivnosti, a operatori ih koriste u svrhu evidencije telekomunikacijskih aktivnosti korisnika, na temelju kojih se formira račun za pružene usluge. Struktura i sadržaj podataka iz zapisa za naplatu telekomunikacijskih usluga su normirani [60], te su neovisni o proizvođaču opreme ili o pružatelju usluge.


Drugu grupu podataka u mreži nazivamo podacima o signalizaciji, a ona sadrži podatke o izmijenjenim signalima između mrežnih elemenata u svrhu kontroliranja procesa komunikacije. Podaci o signalizaciji se pohranjuju radi praćenja performansi rada mreže i analize rada pojedinih sustava, te se koriste u procesu održavanja i optimizacije mreže. Uz dodatak već spomenutih informacija koje su dijelom sadržane u CDR-u (vremenska oznaka početka aktivnosti, identifikacijska oznaka ćelije na koju je terminal spojen, identifikacijska oznaka korisnika), između ostalog, ovi zapisi sadrže informacije o vremenskoj oznaci prestanka telekomunikacijske aktivnosti, informacije o prijelazu terminala s područja pokrivanja jedne ćelije na drugu (engl. *handover*) i promjenu informacije o području lokacije (engl. *Location Area* – LA). Područje lokacija predstavlja područje pokrivanja više ćelija, grupiranih radi optimizacije pružanja usluge. Bilježenje promjene LA odvija se kada terminal prelazi iz područja jednog u drugi LA. Za razliku od CDR-a koji se za potrebe naplate (u smislu izvještaja) konstantno generiraju i šalju u sustav za naplatu, podaci o signalizaciji se ne pohranjuju u bazu podataka, ukoliko se radi održavanja ili praćenja performansi rada mreže to posebno ne odredi.

Zapisi o aktivnostima u javnoj pokretnoj komunikacijskoj mreži (CDR) predstavljaju osnovni materijal za istraživanje u ovoj disertaciji. Iz njih će odgovarajućim postupkom biti izvedeni pokazatelji i indeksi urbane mobilnosti te verificiran i vrednovan postupak procjene urbane mobilnosti stanovnika. Zapisi o telekomunikacijskim aktivnostima u vlasništvu su operatora javnih pokretnih komunikacijskih mreža te mogu sadržavati osjetljive podatke, poput onih o identitetu korisnika, stoga ih je potrebno depersonalizirati. U istraživanju su korišteni javno dostupni skupovi podataka namijenjeni akademskom istraživanju, s unaprijed prikrivenim identitetima korisnika.


2.8.2. Područje pokrivanja baznih stanica (dekompozicija prostora)

Telekomunikacijska domena sastoji se od telekomunikacijske mreže s odgovarajućim elementima koji čine javnu pokretnu telefonsku mrežu, poput baznih stanica, kontrolora baznih stanica, jezgrenog dijela mreže, itd. Riječ je o kontekstualnom, informacijskom svijetu u kojem nastaje CDR zapis. Kod arhitekture telekomunikacijske mreže u kontekstualnom (informacijskom svijetu) nisu važne fizičke lokacije pojedinih elemenata (primjerice, geografska širina ili dužina bazne stanice, MSC-a), već kako su oni međusobno funkcionalno

povezani i koje su njihove međusobne relacije. Položaj u fizičkom svijetu nije važan za njihovu međusobnu funkciju. S druge strane, prometna mreža i entiteti u prometnom sustavu primarno su vezani za fizički svijet, odnosno prometnu infrastrukturu (prometnice, tuneli, mostovi). Prometno inženjerstvo izučava taj dio, odnosno gdje se koji entitet na mreži nalazi i kuda se i kako kreće. Telekomunikacijski sustav pripada u kontekstualnu, informacijsku domenu, dok prometni sustav pripada u fizičku, materijalnu domenu. Dosadašnja istraživanja mobilnosti odnose se na izučavanje kretanja u fizičkom, odnosno materijalnom svijetu. Telekomunikacijska domena generira veliku količinu podataka koju je moguće dovesti u relaciju s fizičkim prostorom. Cilj je iz podataka dostupnih iz kontekstualne domene pokušati razumjeti što se događa u fizičkom, materijalnom svijetu. Kada se skupu podataka iz CDR zapisa pridodaju informacije o položaju baznih stanica u prostoru, napravljen je prvi korak u tranziciji iz kontekstualnog, informacijskog svijeta u fizički, u kojem se mobilnost kao takva odvija. Ukoliko bi se neki od pokazatelja mobilnosti, kao što je broj (ili matrica) putovanja, pokušali uspostaviti samo u telekomunikacijskom svijetu, bez relacije s fizičkim svijetom, ona bi bila vezana samo za telekomunikacijski sustav, a ne za sustav prometa, odnosno mobilnosti i migraciju ljudi u stvarnom, fizičkom svijetu. Stoga je potrebno izvršiti tranziciju iz kontekstualne domene u domenu fizičkog svijeta korištenjem odgovarajućeg postupka. Svaka bazna stanica ima odgovarajuće područje pokrivanja, a čija veličina i oblik ovise o brojnim parametrima, kao što su visina postavljanja, kut postavljanja, konfiguracija tla i okoliša, i tako dalje. Granice pokrivanja baznih stanica nisu izolirane, tako da dolazi do preklapanja područja pokrivanja, pogotovo u urbanim, gusto naseljenim područjima. Površinu pokrivanja bazne stanice stoga je potrebno aproksimirati, kako bi se prostor dekomponirao na način da se točno određena površina u prostoru, korištenjem odgovarajuće metodologije, pridijeli odgovarajućoj baznoj stanici. U literaturi je definirano nekoliko primjera i metoda na koji je sve način moguće izvršiti dekompoziciju prostora. Prostor se može dijeliti na heksagonalne ćelije jednakih veličina. One predstavljaju aproksimaciju pokrivanja pojedine bazne stanice u prostoru i njihov shematski prikaz, a kako je riječ samo o prikazu u kontekstualnoj domeni, ona ne prikazuje stvarno stanje. Riječ je o prikazu pokrivanja prostora baznim stanicama u svrhu razumijevanja njihove međusobne funkcionalne povezanosti, odnosno riječ je o aproksimaciji prostora za potrebe opisa rada telekomunikacijske mreže, tako da njihova primjena u ovom kontekstu nije moguća. Primjer podjele prostora na heksagonalne ćelije dan je na slici 3.



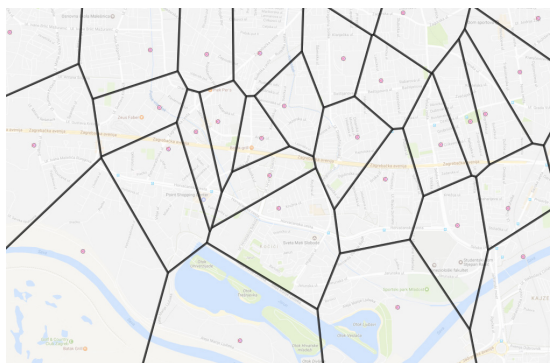
Slika 3. Primjer podjele prostora na heksagonalne ćelije (ilustracija)



Slika 4. Primjer podjele prostora korištenjem rastera polja (ilustracija)

Drugi učestali pristup odnosi se na podjelu prostora na raster polja. Polja imaju jednake dimenzije i pokrivaju cijelo područje obuhvata. Izbor veličine polja obavlja se u ovisnosti o kontekstu i ciljanom području obuhvata. Preporučljivo je izabrati takve dimenzije polja koje odgovaraju području pokrivanja jedne bazne stanice, ali to nije uvjet. Svako polje rastera može sadržavati nijednu, jednu ili više baznih stanica. Korištenje rastera polja rješava se problem varijacija u rasporedu i eventualnim premještanjima ili dodavanjima baznih stanica, jer su polja jednake veličine i međusobno se ne preklapaju te je njihov položaj uvijek isti. Primjer dekompozicije prostora korištenjem rastera polja dan je na slici 4.

Treća metoda jest dijeljenje područja pokrivanja na tzv. Voronojeve ćelije. Voronojeve ćelije predstavljaju posebnu vrstu dekompozicije na diskretne skupove objekata u prostoru. Diskretni skupovi točaka prostora određeni su udaljenošću, pri čemu se položaj bazne stanice uzima kao središte ćelije, a istoj ćeliji pripadaju sve točke koje su bliže središtu te ćelije, nego središtu bilo koje druge ćelije. Točke koje su jednako udaljene od oba središta predstavljaju granicu ćelije [61]–[63]. Primjer dekompozicije urbanog područja pomoću Voronojevog postupka prikazan je na slici 5., pri čemu plave točke označavaju položaj bazne stanice, odnosno središte Voronojeve ćelije, a sive granice omeđuju područje pokrivanja. Voronojeve ćelije daju bolju, realniju i kvalitetnu sliku raspodjele u odnosu na heksagonalne ćelije i na raster polja. Ćelije dobivene Voronojevim postupkom generiraju realniju raspodjelu područja u prostoru između kojih možemo procijeniti mobilnost, odnosno migraciju između tih točaka.




Slika 5. Dekompozicija prostora korištenjem Voronojevog postupka (ilustracija)

Za potrebe daljnje analize, moguće je izvršiti i okrupnjavanje Voronojevih ćelija, kako bi se podjela prostora organizirala na svrsishodan način (na primjer, preklapanje s administrativnim granicama gradskih četvrti, preklapanje s posebnim zonama interesa, kao što su trgovački centri, stadioni, itd.).

2.8.3. Postupak kreiranja zapisa za naplatu telekomunikacijskih usluga

Logička arhitektura sustava naplate u javnim pokretnim komunikacijskim mrežama prikazana je na slici 6. Proces naplate korištenja usluge u javnim pokretnim telefonskim mrežama je normiran [64]. Naplata telekomunikacijskih usluga može se odvijati u približno stvarnom vremenu (engl. online) ili u tzv. izvanmrežnom načinu rada, odnosno naknadnom obradom (engl. offline). U ovoj disertaciji bit će obrađen izvanmrežni sustav naplate u javnim pokretnim komunikacijskim mrežama, koji može biti u funkciji mobilnih mreža druge, treće i četvrte generacije.



Slika 6. Logička arhitektura sustava naplate i tijek informacija u javnoj pokretnoj telefonskoj mreži [64]

Okidač naplate (engl. *Charging trigger function* – CTF) kreira događaje za naplatu temeljem promatranja korištenja mrežnih resursa. U svakoj mreži ili njezinom elementu koji je zadužen za naplatu, CTF predstavlja točku u kojoj se prikupljaju podaci koji se odnose na događaje koje je potrebno naplatiti. U ovom elementu, događaju za naplatu pridjeljuje se informacija o vrsti i tipu aktivnosti koja je evidentirana, te se ta informacija prosljeđuje elementu koji obrađuje podatke za naplatu (engl. *Charging data function* – CDF). Upravo zato, CTF je obvezni element bilo kojeg sustava za naplatu. Unutar CTF-a obavlja se prikupljanje podataka potrebnih za identifikaciju korisnika i vrste usluge, a ti podaci uključuju: identifikacijsku oznaku korisnika, identifikacijsku oznaku vrste i tipa pokrenute usluge, informaciju o podacima koje je potrebno prikupiti u svrhu ispravne naplate, kao i odnos prema uslugama i sesijama koje se ostvaruju. Nakon prikupljanja nužnih informacija, obavlja se detekcija početka naplatnog događaja iz skupa prikupljenih podataka. Ovaj proces prima prethodno prikupljene podatke i utvrđuje pojavu događaja koji treba naplatiti iz skupa od jednog ili više mjernih podataka. Nakon toga, procedura grupira naplatne događaje koji odgovaraju prethodno definiranim kriterijima te ih prosljeđuje prema CDF-u putem Rf-a (referentna točka). Naplatni događaji pružaju informacije potrebne za naplatu korištenja usluge, tj. karakteriziraju korištenje mrežnih resursa zajedno s identifikacijom uključenih korisnika. Prosljeđivanjem podataka u stvarnom vremenu završava se uloga ovog elementa u lancu naplate.

Element za naplatu putem referentne točke Rf zaprima podatke od sustava za okidanje naplate. Koristi zaprimljene informacije kako bi oformio CDR. CDR može biti kreiran od jednog događaja, ali može biti formiran i od strane nekoliko događaja. Svaki događaj koji zahtijeva naplatu može biti sadržan samo u jednom CDR-u. CDR može sadržavati više događaja ili aktivnosti koje je potrebno naplatiti. Sustav za formiranje CDR-ova mora omogućiti nastanak zapisa u približno stvarnom vremenu. Odnos između CDF-a i CTF-a može biti 1:1 ili 1:n. Svi podaci koji se koriste za izradu jedinstvenog CDR-a moraju potjecati iz istog mrežnog elementa (engl. *network element* - NE). Rezultat ovog procesa jest kreiranje zapisa CDR-a s unaprijed poznatim formatom sadržaja i zapisima.

CDR zapis kreiran u CDF-u prosljeđuje se elementu koji se zove pristupnik za naplatu (engl. *Charging Gateway Function* – CGF) putem Ga referentne točke. CGF služi kao pristupnik između mreže po 3GPP standardu i sustava za naplatu (engl. *billing domain* – BD). Koristi Bx referentnu točku za transfer datoteka s CDR-om prema BD. Odnos između CDF-a i CGM-a jest m:1, pri čemu jedan ili više CDF-ova može prosljeđivati CDR-ove u jedan CGF.

Osnovne funkcije CGF-a su prihvatanje informacija iz CDR-a u približno stvarnom vremenu, zatim predprocesiranje CDR-a u smislu provjere njegove ispravnosti, konsolidiranosti i formata zapisa. CGF je zadužen za rukovanje pogreškama, kao i pohranu zapisa. Odgovoran je za rutiranje i filtriranje zapisa, kao što je primjerice organizacija CDR-ova u odnosu na kriterije, poput vrste CDR-a, CDF iz kojeg dolazi i slično. CGF je zadužen i za sve operacije s datotekama, kao što su kreiranje, otvaranje, zatvaranje i brisanje datoteka te na kraju transfer datoteka u BD.

Sustav za naplatu je dio pokretne ćelijske mreže i smješten je izvan jezgrenog dijela mreže. On zaprima i obrađuje CDR podatke iz jezgrenog dijela mreže, odnosno iz CGF-a. Sadrži funkcionalnosti koje omogućuju medijaciju naplate, samu naplatu te podršku za različite aplikacije, kao što je primjerice statistička obrada. U pravilu, CDR zapis sadrži sljedeće osnovne podatke:

- broj pozivatelja (A- broj),
- pozivani broj (B-broj),
- datum i vrijeme poziva,
- trajanje poziva,
- broj telefona kojem će biti naplaćena ta usluga,
- ID indeks telefonske centrale koja obavlja zapis,
- jedinstveni identifikator poziva,
- dodatne podatke ukoliko su korišteni za rutiranje poziva,
- telekomunikacijsku rutu kojom je poziv ušao u centralu,
- rutu kojom je poziv izašao iz centrale,
- vrstu poziva i
- zabilježene greške.

Premda je normiran, konačni format i sadržaj CDR zapisa može varirati u ovisnosti od proizvođača telekomunikacijske opreme koja ga generira.

2.8.4. Depersonalizacija podataka

Obzirom da je u slučaju CDR-a riječ o osjetljivim podacima koji sadrže osobne informacije o korisniku, poput pozivanih brojeva telefona, lokacije baznih stanica na koje je bio spojen i slično, nije ih moguće koristiti van telekomunikacijskog okruženja ukoliko nije proveden proces anonimizacije. Sustav za anonimizaciju je poseban dio logičke arhitekture koji potpuno razdvaja identitet korisnika od obrade podataka i analitike kroz različite tehnike filtriranja i kriptiranja, što prati i razdvajanje timova, ovlasti i procesa. Cilj anonimizacije

podataka jest ukloniti sve osjetljive informacije koje mogu razotkriti podatke o korisnicima, a istovremeno zadržati sve vrijednosti i strukturu podataka važnu za kasniju obradu [65]. Anonimizacija podataka osigurava da osjetljivi podaci ne mogu biti zlouporabljani, ukoliko se predaju na korištenje vanjskom sustavu, budu objavljeni ili ukradeni. Anonimizacija se obavlja na podacima u datotekama, bazama podataka ili podatkovnim centrima. U procesu anonimizacije podaci se obično ekstrahiraju iz raznovrsnih izvora podataka, provjeravaju se, transformiraju i potom ponovno pohranjuju. Uopćeno, postoje dva pristupa anonimizaciji podataka od kojih prvi koristi tehniku nasumičnosti (engl. *randomisation*), a drugi tehniku poopćavanja (engl. *generalisation*) [65]. Anonimizirani podaci za krajnju obradu pohranjuju se u odgovarajućim bazama podataka. U tim bazama podataka oni su dostupni za analizu odgovarajućoj aplikaciji, kao što je primjerice procjena urbane mobilnosti.


2.8.5. Dosadašnja istraživanja mobilnosti temeljena na podacima iz javnih pokretnih komunikacijskih mreža

Mogućnosti korištenja podataka iz javnih pokretnih komunikacijskih mreža za potrebe analiza u području tehnologije prometa i transporta analizira se čitav niz godina, što je vidljivo i iz mnogobrojne znanstvene i stručne bibliografije iz ovog područja. Autori se slažu kako su se do sada uobičajene metode prikupljanja podataka o urbanoj mobilnosti (ankete, istraživanje navika, mjerenja na ograničenom prostoru ili presjeku) pokazale kao nepraktične, skupe i neefikasne. Koriste mali uzorak ispitanika, imaju ograničeno prostorno i vremensko pokrivanje te se provode u često neodgovarajućim vremenskim intervalima (veliki razmaci između prikupljanja podataka). Kao alternativni izvor podataka za izučavanje obrazaca kretanja osoba u urbanim aglomeracijama u velikoj mjeri istraživali su i potencijal javnih pokretnih komunikacijskih mreža, koji je okarakteriziran kao novi izvor podataka koji je još potrebno dodatno istražiti.

Uopćeno, zaključak je da ovaj novi izvor podataka predstavlja veliki potencijal u istraživanju urbane mobilnosti, prvenstveno jer obuhvaća gotovo cijeli uzorak stanovništva (korištenje mobilnih uređaja karakterizira visoka stopa penetracije u skoro svim razvijenim zemljama), a povezan s informacijama o položaju baznih stanica, može približno rekonstruirati i kretanje korisnika. Također, povećanjem broja korisnika mobilnih telefona, smanjena je i gotovo u potpunosti eliminirana razlika između broja osoba koji imaju mobilni telefon i onih

koji ih nemaju, čime je ovaj izvor podataka postao još prikladniji za istraživanje mobilnosti [20].

Pionirom istraživanja urbane mobilnosti temeljem podataka iz javnih pokretnih komunikacijskih mreža u svrhu procjene urbane mobilnosti smatra se Carlo Ratti, koji se bavi istraživanjem unutar laboratorija „Senseable city“ [66], [67]. On je uvidio potencijal takve vrste podataka u svrhu analize i vizualizacije urbanih aktivnosti i njene promjene kroz prostor i vrijeme. Temeljem podataka o broju i trajanju glasovnih poziva s baznih stanica identificirao je zone atrakcije te područja na kojima se korisnici zadržavaju na primjeru grada Graza [66], [67]. Zanimljivo je da je vizualizacija podataka o intenzitetima korištenja mobilnih telefona (broj poziva) i dužini razgovora služila kao umjetničko djelo, te je kao takva izlagana na umjetničkim izložbama. Primjer tih vizualizacija dan je na slici 7.



Slika 7. Vizualizacija telekomunikacijskih aktivnosti korisnika u gradu Grazu [66]

Ratti je sa suradnicima i autor naziva „Krajoblik mobilnosti“ (engl. *Mobility landscapes*) koji je formirao u svrhu analize i vizualizacije dinamike dnevnih migracija korisnika u urbanoj aglomeraciji, a temeljem podataka o njihovim telekomunikacijskim aktivnostima. Uvidio je i mogućnost primjene podataka u analizi kretanja putnika između gradova, za praćenje kretanja stanovništva u incidentnim i općeopasnim situacijama, kao i za analizu karaktera migracija tijekom radnih dana i vikendom. Uz veliki potencijal novog izvora podataka, zaključio je kako je najveći nedostatak upravo problematika dobavljanja takve vrste podataka, podacima, kako u tehničkom, tako i u pravnom smislu.

Williams [68], je sa svojim multidisciplinarnim timom zaključio kako su podaci iz javnih pokretnih telefonskih mreža postali dostupni za analizu kretanja korisnika na način kojima dosadašnje metode, poput anketa, popisa stanovništva i slično, ne mogu parirati kada je

u pitanju veličina uzorka i preciznost. Williams je definirao dvije dimenzije mobilnosti; i to mobilnost kao funkciju frekvencije kretanja i prostornog dosega. Frekvencija kretanja predstavlja broj putovanja koje pojedini korisnik ostvari, pri čemu, što je frekvencija veća, veće je i sudjelovanje u mobilnosti. Druga dimenzija jest prostorni doseg, pri čemu vrijedi: koliko daleko osoba putuje, veće je i njeno sudjelovanje u mobilnosti. Definirao je prvi pokazatelj mobilnosti kao broj putovanja koji se odnosi na broj mrežnih aktivnosti koje je korisnik obavio na ćelijama različitim od prethodne. Zaključio je kako temeljem podataka iz CDR-a nije moguće odrediti koliko je dugo pojedina osoba boravila na pojedinoj lokaciji na kojoj se nalazila, ukoliko nije obavljala mrežne aktivnosti. Drugi pokazatelj mobilnosti jest ukupan broj posjećenih područja pokrivanja kojima se određuje koliko je područja unutar urbane aglomeracije korisnik posjetio. Predlaže i treći pokazatelj, odnosno pokazatelj omjera broja posjećenih ćelija u odnosu na ukupan broj ćelija na trajektoriji kretanja [68].

Calabreze [12],[69] je sa suradnicima za potrebe analize kretanja korisnika u urbanoj aglomeraciji koristio više izvora podataka. Koristio je podatke iz zapisa za naplatu telekomunikacijskih usluga, podatke iz signalizacije javne pokretne komunikacijske mreže, podatke sa konvencionalnih brojača prometa, kao i podatke o kretanju taksi vozila i vozila javnog gradskog prijevoza temeljem zapisa iz njihovih internih sustava za pozicioniranje. Zaključio je kako je fuzija podataka iz različitih izvora prikladna za određivanje pokazatelja urbane mobilnosti [12]. Calabreze je također definirao i procjenu ukupne osobne mobilnosti, koja se sastoji od sume pravocrtnih udaljenosti između područja koje je korisnik posjetio u danu, pri čemu je razlikovao osobnu mobilnost koja je vezana za vozilo (izražava se u vozilo-kilometrima), kao i osobnu mobilnost koja je vezana za ostale vidove prometa. Podatke o modalnoj razdiobi prikupio je anketom. Područje obuhvata podijeljeno je na raster polja dimenzija 500 x 500 metara [69].

Dash i suradnici su proces određivanja matrica putovanja definirali kao postupak definiranja putovanja između izvora i odredišta, pri čemu je glavni naglasak stavljen upravo na model određivanja lokacija na kojima je korisnik boravio odgovarajući vremenski period, odnosno na kojima je po njihovoj definiciji boravio. Izvor putovanja je definiran kao lokacija koju pokriva jedna ili više baznih stanica, a na kojoj je korisnik boravio unaprijed definiran vremenski period, tako da se isključi mogućnost da je tamo bio samo u tranzitu. Putovanje definiraju kao pomak između dva područja boravka. U daljnjoj razradi definirali su i prijedeni put korisnika, na način da su putovanju pridijelili najvjerojatniju cestovnu rutu, korištenjem

kriterija najkraćega putovanja. Na kraju su svakom korisniku pridijelili takozvani rezultat mobilnosti, koji se sastoji od ukupnog broja putovanja pojedinog korisnika, broja lokacija na kojima se zadržavao i udaljenost po putovanju [70].

Pulselli [71] je sa suradnicima temeljem podataka iz javnih pokretnih komunikacijskih mreža prikazao gradove kao živi ekosustav koji se konstantno mijenja i reagira na događaje kao što su utakmice, koncerti, zatvaranja ulica za promet i slično. Zaključio je kako su podaci iz CDR-ova iskoristivi za praćenje kolektivnih ponašanja, perturbacije i fluktuacije koje se odvijaju u složenim urbanim sredinama. Analizirao je telekomunikacijske aktivnosti korisnika i prikazao kako zapisi o njima pokazuju intenzivnu aktivnost na području rezidencijalnih četvrti van uobičajenog radnog vremena, kao i intenzivnu aktivnost u poslovnim zonama i centru grada tijekom radnog vremena, odnosno pojačanu aktivnost na području transportnih čvorova između ovih faza. Također, koristio je i dodatne podatke iz javnih pokretnih komunikacijskih mreža, kao što su kut prilaza korisnika ćeliji, karakterističnu mjeru udaljenosti (engl. *timing advance*) te snagu signala, s ciljem povećanja preciznosti lociranja u odnosu na postupak koji koristi samo položaj bazne stanice [71].

Reades je sa suradnicima relativizirao lokacije kako bi identificirao relativni intenzitet aktivnosti unutar urbane aglomeracije. Urbanu aglomeraciju je podijelio na područja pokrivanja urbanih ćelija, koje je potom relativizirao u odnosu na broj poziva u svim ćelijama u tom razdoblju, da bi potom bile normalizirane sa svojom prosječnom vrijednošću u definiranom vremenskom razdoblju. Rezultati su ukazali na značajne razlike u aktivnostima korisnika u odnosu na doba dana, kao i u odnosu na dane u tjednu. Potom je grupirao područja sa sličnim intenzitetom aktivnosti u određenom vremenu, te na taj način definirao područja po namjeni (rezidencijalne četvrti, poslovne četvrti i slično) [72].

Trevisani [73] se sa suradnicima bavio procjenom preciznosti pozicioniranja, tako da je na temelju istraživanja u Rimu i New Yorku mogao odrediti, za mobilnu mrežu druge generacije, prosječnu pogrešku pozicioniranja. Testirao je pozicioniranje putem mobilne mreže, koje je potom uspoređivao s podacima prikupljenima pomoću GPS-a, koje je uzimao kao referentne. U urbanim uvjetima greška pozicioniranja je bila 480 metara, u ruralnom području greška pozicioniranja je iznosila 750 metara, a na otvorenom, nenaseljenom prostoru (autoceste) greška pozicioniranja je iznosila otprilike 1 kilometar. Također, dokazao je da je u 63 % vremena mobilni telefon bio povezan s najbližom baznom stanicom mobilne mreže [73].

Ahas [74] je sa suradnicima koristio podatke o uspostavljenim i zaprimljenim pozivima, ulaznim i izlaznim SMS porukama te pristupu internetu kako bi temeljem analize 9,2 milijuna zapisa procijenio kretanje turista po Estoniji. Analizirao je zemlju podrijetla turista i vrijeme zadržavanja na pojedinim destinacijama. Rezultat istraživanja je korelirao s evidencijom kretanja i zadržavanja turista državne turističke zajednice, pri čemu je utvrđen visoki koeficijent korelacije 0,97. Kao ključni nedostatak identificirao je činjenicu da turisti koji ne koriste mobilni telefon nisu evidentirani.

Julian Candia [75] je sa suradnicima koristio uzorke telekomunikacijskih aktivnosti šest milijuna korisnika iz neimenovane države koji su prikupljeni tijekom mjesec dana, te su sadržavali vrijeme obavljanja telekomunikacijske aktivnosti, identifikacijsku oznaku bazne stanice i depersonaliziranu oznaku korisnika. Utvrdili su korelaciju između broja ostvarenih poziva i prijeđene udaljenosti, pri čemu su vršne vrijednosti zabilježene u jutarnjim i popodnevnim razdobljima, a najniže vrijednosti zabilježene su noću.

Nicola Caceres [76], [77] je sa suradnicima prvi razmatrao mogućnost korištenja podataka iz zapisa za naplatu telekomunikacijskih usluga za identifikaciju matrica putovanja. Zaključio je kako u tom području postoji veliki potencijal, s naglaskom da je za točno određivanje matrica putovanja potrebno analizirati podatke prikupljene u dužem vremenskom razdoblju. U nedostatku stvarnih podataka, korišteni su simulirani podaci iz mobilne mreže. Temeljem simuliranih podataka o korištenju mobilnih telefona i stvarnih podataka o brojanju prometa, zaključili su da je točnost određivanja matrica putovanja u odnosu na stvarno stanje 95 %, pri čemu je ulazni podatak za simulaciju (broj korisnika) ponderiran njihovim tržišnim udjelima, a ukupan broj korisnika je procijenjen temeljem statističkih pokazatelja o penetraciji broja korisnika. Broj korisnika je mapiran i na broj automobila, pri čemu je svakom automobilu pridijeljen onoliki broj korisnika koliko ih se u prosjeku u automobilu nalazi (utvrđeno brojanjem prometa) [76], [77].

Zahui Qu je sa suradnicima temeljem podataka iz zapisa za naplatu telekomunikacijskih usluga razvio model predikcije kretanja korisnika u urbanim područjima. Motiv istraživanja bio je definirati obrazac kretanja korisnika u svrhu prometnog planiranja, kao i u svrhu praćenja širenja zaraza ili bolesti. Zaključio je da je 93 % putovanja predvidivo temeljem saznanja o uobičajenim obrascima kretanja korisnika [78].

Bengstsoon je sa suradnicima temeljem podataka iz zapisa za naplatu telekomunikacijskih usluga pratio kretanje stanovništva poslije potresa na Haitiju tijekom 2010.

godine. Koristio je anatomizirane podatke dva milijuna pretplatnika kako bi utvrdio iz kojeg su dijela teritorija stanovnici otišli [79].

Temeljem podataka iz mobilnih mreža, i to prvenstveno korištenjem podataka o promjenama bazne stanice (prekapčanje, engl. *handover*), Thiessenhusen je sa suradnicima pokušao odrediti količinu prometa na cestovnoj mreži. Podaci o prekapčanju su služili kao okidač kojim se detektirao broj terminala koji su „prošli“ kroz virtualni brojač prometa. Utvrdio je kako je broj tako registriranih mobilnih telefona i broj vozila koji su detektirani tradicionalnim brojačima prometa visoko koreliran [80].

Ygnace je sa suradnicima analizom podataka o signalizaciji na radijskom sučelju mreže pokušao odrediti brzinu kretanja korisnika po mreži. Estimirao je položaj vozila prilikom svake razmjene signalizacijske poruke između mobilnog terminala i mreže (preciznost otprilike 150 metara), te je na osnovu tako određenih lokacija odredio brzinu i smjer kretanja vozila. Usporedbom s podacima s konvencionalnih brojača prometa na tim lokacijama, utvrdio je da je pogreška na razini 10 % u ruralnom području, odnosno 28 % u urbanom području [81].

Lu je sa suradnicima identificirao sljedeće pokazatelje mobilnosti i to: a) broj ćelija (broj ćelija s koje je korisnik obavljao mrežne aktivnosti u određenom vremenskom razdoblju), b) pravocrtnu udaljenost (pravocrtni prijeđeni put) kao sumu svih pravocrtnih udaljenosti između baznih stanica s kojih je ostvarena uzastopna aktivnost, zatim c) najveći prijeđeni put kao pravocrtnu udaljenost između dvije najudaljenije bazne stanice na kojima je korisnik imao svoju aktivnost te d) pokazatelj centra mase. Pokazatelj centra mase izračunava se tako da se uspostavlja centri mase za sve ćelije koje je korisnik koristio te se potom računa pravocrtna udaljenost između svih centara mase na kojima je zabilježena korisnikova aktivnost. Vrijednost centra mase je korijen srednje vrijednosti kvadrata tih udaljenosti [79].

Istraživački tim okupljen oko Marte C. Gonzales uopćeno je analizirao mogućnost rekonstrukcije kretanja korisnika te definiranja općeg modela predviđanja obrasca kretanja korisnika temeljem podataka iz javnih pokretnih komunikacijskih mreža. Poseban naglasak stavljen je na mogućnost definiranja matrica putovanja temeljem analize skupa podataka iz CDR-a. Analizom podataka iz CDR-a određene su matrice putovanja koje su potom validirane korištenjem postojećih matrica putovanja dobivenih tradicionalnim metodama, kao što su ankete stanovništva, odnosno podaci s brojača prometa. Također, s obzirom da se kao izvor putovanja uzima onaj položaj u kojem je korisnik počeo obavljati telekomunikacijsku aktivnost (koja se ne mora nužno poklopiti sa stvarnim izvorom putovanja), uveli su pojam tzv. prolaznih

matrica putovanja, koje odgovaraju putovanjima s izvorima i odredištima registriranim u CDR zapisima. Korišteni su i drugi izvori podataka (podaci o trajektorijama kretanja vozila javnog gradskog prijevoza, podaci o kretanju taksi vozila, podaci iz sustava pametnih karata javnog gradskog prijevoza), kao i alati za mikrosimulaciju prometnih tokova. Zaključak je kako je korištenje podataka iz komunikacijskih mreža posebno prikladno za generiranje matrica putovanja iznimno kompleksnih urbanih područja, gdje postoji ograničena mogućnost primjene tradicionalnih metoda, kao i gdje prevladava heterogen obrazac korištenja zemljišta, te u urbanim područjima u kojima su putovanja brojna i često asimetrična. Također, cilj ovog istraživačkog tima je uspostava metodologije i sustava za praćenje i definiranje obrazaca individualne mobilnosti korisnika u stvarnom vremenu. Velika pažnja posvećena je i reprezentativnosti uzorka. Temeljem istraživanja u Rio de Janeiru i Bostonu, pri čemu su analizirani podaci o komunikacijskim aktivnostima 2,8 milijuna korisnika u odnosu na 6,3 milijuna stanovnika u Rio de Janeiru i 2 milijuna korisnika u odnosu na 4,5 milijuna stanovnika u Bostonu, zaključeno je da obuhvaćeni uzorak korisnika jednog mobilnog operatora predstavlja reprezentativni uzorak populacije, s tim da reprezentativnost uzorka raste s udjelom operatora na tržištu (raste broj obuhvaćenih korisnika), kao i s rastom broja telekomunikacijskih aktivnosti [14], [62], [75], [82]–[84].

Također, autori su identificirali i proces određivanja matrica putovanja temeljem depersonaliziranog podskupa zapisa za naplatu telekomunikacijskih usluga. Definiran je postupak određivanja izvora i odredišta putovanja, kao i odgovarajući vremenski i prostorni filteri koji eliminiraju takozvana lažna putovanja, odnosno ona koja se nisu dogodila. Potom se „prebrojavaju“ putovanja između pojedinih područja, temeljem kojih se, za unaprijed definirane vremenske raspone, definiraju matrice putovanja [85].

Sukladno pregledu literature u ovom području, možemo zaključiti da su autori u posljednja dva desetljeća posvetili veliku pažnju mogućnosti korištenja podataka iz zapisa za naplatu telekomunikacijskih usluga u svrhu praćenja prometnih tokova, urbanog planiranja i slične namjene. Autori su dokazali da je uzorak obuhvaćen CDR zapisom reprezentativan, da je pouzdanost metode visoka i da je visok koeficijent korelacije usporedbom tako generiranih pokazatelja s onim pokazateljima iz tradicionalnih izvora. Predložen je niz različitih pokazatelja koji se mogu izvesti iz podskupa podataka, premda nisu unificirani postupci njihovog dobivanja i izračuna. Većina autora identificira jedan pokazatelj urbane mobilnosti (primjerice matrice putovanja), s tim da je češće naglasak na osobnoj mobilnosti, odnosno na mobilnosti pojedinog

korisnika unutar urbane aglomeracije, a rjeđe na procjeni mobilnosti na razini urbane aglomeracije. Također, u ovisnosti o namjeni i cilju istraživanja, pokazatelje određuju za vremenski okvir u rasponu od nekoliko sati pa do jedne godine [20], [9].

Zaključno, u dosadašnjim istraživanjima nije zabilježeno kreiranje indeksa urbane mobilnosti temeljem podataka iz zapisa za naplatu telekomunikacijskih usluga u javnim pokretnim telekomunikacijskim mrežama, koji bi se kao rezultat fuzije odnosnih pokazatelja mobilnosti (broj putovanja, trajanje putovanja, euklidska udaljenost) mogao koristiti u svrhu procjene urbane mobilnosti.

3. METODOLOGIJA ISTRAŽIVANJA

3.1. Pregled metodologije

U ovom poglavlju bit će definirana metodologija za uspostavu ekspertnog sustava za izračun indeksa urbane mobilnosti. Ekspertni sustav se definira kao sustav u koji je ugrađeno ljudsko znanje uz pomoć kojeg on rješava probleme iz nekog specifičnog područja na sličan način kako ih rješava čovjek-stručnjak (ekspert) [86]. Iz zapisa o telekomunikacijskim aktivnostima u javnim pokretnim komunikacijskim mrežama ekstrahiran je odgovarajući podskup podataka koji sadrži sljedeće informacije: vremenski trenutak ostvarenja telekomunikacijske aktivnosti, položaj bazne stanice na koju je korisnik spojen tijekom obavljanja telekomunikacijske aktivnosti i zamjensku identifikacijsku oznaku korisnika koja prikriva stvarni identitet. Navedeni podaci koriste se za definiranje sljedećih pokazatelja urbane mobilnosti: broj migracija (broj putovanja), vremensko trajanje te euklidska udaljenost. Ti pokazatelji koristit će se kao ulaz za model. Prvi pokazatelj je pokazatelj broja putovanja. Primjenjuje se algoritam za određivanje ovog pokazatelja, a rezultat je matrica putovanja čija polja sadrže ukupan broj putovanja između određenih parova baznih stanica (pripadajućeg urbanog prostora) u predefiniranom vremenskom okviru. Drugi pokazatelj je pokazatelj trajanja putovanja, a koji se izračunava kao srednja vrijednost trajanja putovanja između određenih parova baznih stanica u vremenskom okviru. Nakon toga određuje se i treći pokazatelj, pokazatelj (euklidske) udaljenosti između parova baznih stanica. Sljedeći korak je definiranje ekspertnog sustava koji uzima prethodno određene indekse te ih na osnovu „naučenog znanja“ dovodi u odgovarajuću vezu za procjenu ukupne urbane mobilnosti. Učenje je zasnovano na postupku „crpljenja znanja“ od širokog kruga eksperata u području urbane mobilnosti. Tehnički, ovo crpljenje znanja je provedeno postupkom anketiranja, ekspertni sustav je uspostavljen temeljem rezultata ankete, a korištenjem metode neizrazite logike, odnosno tzv. ANFIS tehnike strojnog učenja. Rezultat je ekspertni sustav kojim je definiran i razvijen model za izračun indeksa urbane mobilnosti temeljem pokazatelja izvedenih iz zapisa o telekomunikacijskim aktivnostima korisnika javnih pokretnih komunikacijskih mreža. Indeks urbane mobilnosti temeljem predloženog modela izračunava se za svaki par baznih stanica (odgovarajućih urbanih cjelina), i kao takav predstavlja udio u ukupnom indeksu mobilnosti te stoga nosi naziv parcijalni indeks (parcijalnost se odnosi na to što uzima u obzir samo dio promatrane aglomeracije-prostora). Vrijednosti parcijalnih indeksa urbane mobilnosti se potom

koriste za izračun indeksa urbane mobilnosti cijelog područja i to za predefinirani vremenski okvir.

3.2. Postupak određivanja indeksa urbane mobilnosti

Postupak određivanja indeksa urbane mobilnosti opisan je kroz deset točaka koje su detaljno opisane u nastavku teksta. Postupak procjene uzima u obzir i određene pretpostavke.

Pretpostavke su:

1. Putovanje je kretanje korisnika između dvije bazne stanice javne pokretne telefonske mreže (odnos između dva urbana područja) na kojima je ostvario telekomunikacijsku aktivnost (poziv, SMS, pristup internetu) koja je registrirana u CDR zapisu, uzimajući u obzir pretpostavke vezane za trajanje, udaljenost i brzinu putovanja (3-5) te prijedenu udaljenost [61], [70], [85].
2. Lažno kretanje ili lažno putovanje jest putovanje korisnika koje je identificirano promjenom bazne stanice, a koje se zapravo nije dogodilo, odnosno nije došlo do fizičkog pomaka korisnika. Pojava se javlja uslijed načina rada javne pokretne telefonske mreže i tendencije da se optimizira rad pojedinih baznih stanica prebacivanjem suviška korisnika na druge bazne stanice u području pokrivanja koje su u tom trenutku pod manjim opterećenjem (engl. *load balancing*) [61], [70], [85].
3. Vremenski prag (engl. *time threshold*) služi za filtriranje zapisa o „lažnim“ kretanjima i iznosi $10 \text{ min} < x < 60 \text{ min}$, što znači da se eliminiraju sva putovanja koja su trajala kraće od 10 ili duže od 60 minuta [61], [70], [85].
4. Prostorni prag (engl. *spatial threshold*) služi za filtriranje zapisa o „lažnim“ kretanjima kojim se eliminiraju sva putovanja kraća od 1 km [61], [70], [85].
5. Prag brzina je eliminiranje svih putovanja za koje se, uslijed vrijednosti pokazatelja brzine, pretpostavlja da nisu realna ili su rezultat pogreške. Definiran je prag brzine od 100 km/h, tako da sva putovanja koja su imala prosječnu brzinu veću od 100 km/h nisu uzeta u obzir.
6. Mobilnost se korištenjem ovog postupka može procjenjivati za proizvoljan vremenski okvir. Za potrebe ovog istraživanja definirano je da se mobilnost procjenjuje za vremenske intervale od tri sata, tako da se dan dijeli na osam trosatnih intervala.
7. Urbana lokacija je područje pokrivanja jedne bazne stanice u prostoru definirane jedinstvenim identifikatorom stanice, zemljopisnim koordinatama položaja bazne stanice u prostoru te površinom pokrivanja u obliku Voronojeve ćelije.

Po definiranju pretpostavki, slijedi opis postupka procjene mobilnosti, a koraci su opisani sukladno numeraciji na slici 8.



Slika 8. Hodogram aktivnosti određivanja indeksa urbane mobilnosti

3.2.1. Ulazni podaci

3.2.1.1. Učitavanje podskupa podataka

U hodogramu je označeno kao korak 1.1. Ulazni podatak u model jest podskup zapisa iz CDR-a koji je na odgovarajući način unaprijed anonimiziran (depersonaliziran) te u kojem su uklonjene sve informacije, osim privremene identifikacijske oznake korisnika, vremenskog početka telekomunikacijske aktivnosti i zemljopisnog položaja bazne stanice na koju je korisnik bio spojen tijekom obavljanja telekomunikacijske aktivnosti. Za proces depersonalizacije sadržaja kao i prilagodbu sadržaja zadužen je vlasnik podataka, operater telekomunikacijskih usluga. Datoteka sadrži vrijednosti odvojene zarezom ili nekim drugim uobičajenim formatom za razdvajanje podataka (praznine, točka zarez, itd.) i učitava se u računalnu okolinu koja je opisana u poglavlju 5.1. Prikaz primjera sadržaja datoteke sa strukturiranim sadržajem podskupa iz CDR zapisa dan je na slici 9.

```
0055555559,23:32:58,114.043854,22.530757
0055555560,23:15:24,114.043854,22.530757
0055555561,23:52:57,114.043854,22.530757
0055555561,23:51:43,114.043854,22.530757
0055555562,23:40:12,114.0643056,22.6354861
0055555563,23:39:28,114.043854,22.530757
0055555564,23:15:34,114.043854,22.530757
0055555565,18:30:28,113.8201389,22.7508333
0055555565,18:30:44,113.8201389,22.7508333
0055555566,23:18:25,114.043854,22.530757
0055555567,23:45:08,114.043854,22.530757
0055555568,23:13:18,114.043854,22.530757
0055555569,23:58:56,114.043854,22.530757
0055555570,22:33:10,114.043854,22.530757
0055555570,22:36:28,114.043854,22.530757
```

Slika 9. Primjer strukturiranog i depersonaliziranog podskupa podataka koji se koristi za analizu. Podaci preuzeti od [87].

3.2.1.2. Konverzija ulaznih podataka u tablicu

U hodogramu je označeno kao korak 1.2. Datoteka s podacima (slika 9.) transformira se u tablicu koja sadrži sljedeća polja: KORISNIK_ID, t (vrijeme), LAT i LONG (tablica 9.).

Tablica 9. Format tablice koja je rezultat konverzije ulaznih podataka

KORISNIK_ID	t (vrijeme)	LAT	LONG

3.2.1.3. *Kreiranje tablice baznih stanica*

U hodogramu je označeno kao korak 1.3. U ovom koraku identificiraju se bazne stanice koje se pohranjuju u pripadajuću tablicu. Uspostavlja se varijabla ID_LOKACIJE koja sadrži jedinstveni ID za isti par LAT, LONG, s njima se uparuje te se dodaje u „Tablicu baznih stanica“.

Rezultat su vrijednosti (primjer kao u tablici 10.) LAT, LONG kojima je pridijeljen jedinstven ID_LOKACIJE **(1,2,3,...,n)**.

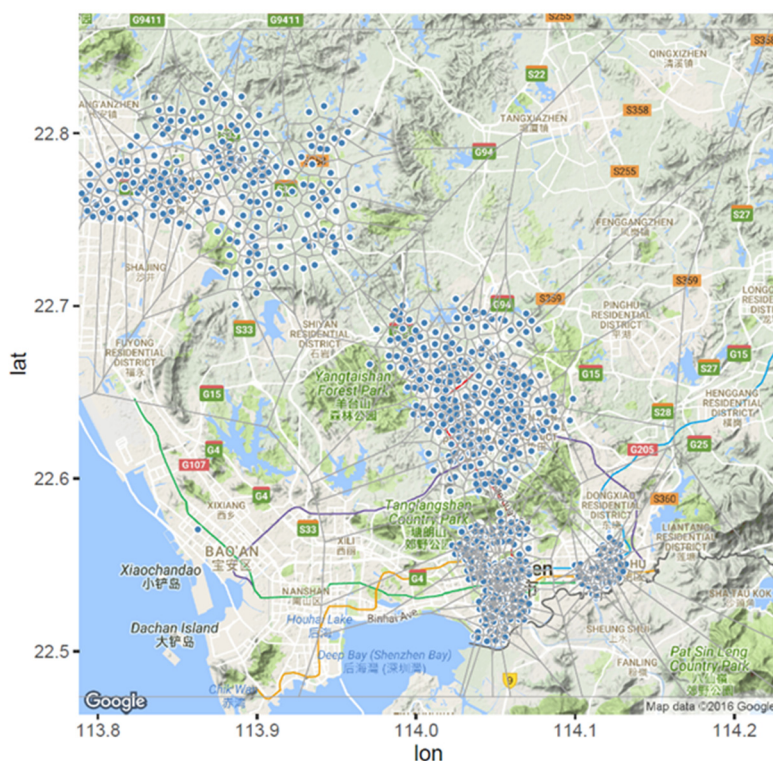
Tablica 10. Tablica baznih stanica

LAT	LONG	ID_LOKACIJE
...	...	1
...	...	2
...	...	3
...	...	4

3.2.1.4. *Dekompozicija prostora*

U hodogramu je označeno kao korak 1.4. U ovom koraku se svakoj baznoj stanici identificira područje pokrivanja primjenom takozvanog Voronojevog postupka tako da se područje istraživanja na kojem se procjenjuje urbana mobilnost dijeli na područja pokrivanja u obliku Voronojeve ćelije [61]–[63]. Primjer dekompozicije urbanog područja pomoću Voronojeve postupka prikazan je na slici 10., pri čemu plave točke označavaju položaj bazne stanice, odnosno središte Voronojeve ćelije, a sive granice omeđuju područje pokrivanja. Za potrebe daljnje analize, moguće je izvršiti okrupnjavanje Voronojevih ćelija, kako bi se podjela

prostora organizirala na svrsishodan i učinkovit način (na primjer, preklapanje s administrativnim granicama gradskih četvrti, preklapanje s posebnim zonama interesa, kao što su trgovački centri, stadioni, itd.). Proračun pokazatelja prvo se odvija na razini svih parova baznih stanica, odnosno na razini njima pripadajućih urbanih prostora, a potom, ukoliko za tim ima potrebe, radi se proračun pokazatelja za urbana područja koja mogu uključivati i više baznih stanica.



Slika 10. Dekompozicija prostora u Voronojeve ćelije na primjeru grada Shenzena na podlozi Google Maps [61]

3.2.2. Proračun udaljenosti

3.2.2.1. Proračun euklidske udaljenosti

U hodogramu je označeno kao korak 2.1. U ovom koraku obavlja se proračun euklidske udaljenosti između svakog para baznih stanica (odnosno parova urbanih područja) u tablici. Vrijednosti se pohranjuju u tablicu za svaki par baznih stanica. Cilj ovog koraka jest identificirati pravocrtne udaljenosti između svakog para baznih stanica (kao aproksimacija prometnih udaljenosti), koje će se koristiti za izračunavanje prijedjenih pravocrtnih udaljenosti između svih parova baznih stanica između kojih je zabilježeno putovanje, kao i za proces

filtriranja podataka kako bi se osiguralo poštivanje prostornog praga za podatke koji se neće uzimati u obzir. Udaljenost između dvije lokacije računa se pomoću Haversinove formule (5), [88]. Udaljenost između dvije bazne stanice dobivena Haversinovom formulom predstavlja pokazatelj $C(i, j)$ (6):

$$a = \sin^2\left(\frac{lat2-lat1}{2}\right) + \cos(lat1) * \cos(lat2) * \sin^2\left(\frac{long2-long1}{2}\right)$$

$$d = R * \text{atan2}(\sqrt{a}, \sqrt{1-a}) \quad (5)$$

$$C(i, j) = d(i, j) \quad (6)$$

pri čemu je:

- $R=6371$ – km prosječna vrijednost radijusa Zemlje,
- $C(i, j)$ – euklidska udaljenost između svakog para baznih stanica,
- $long_{1,2}$ – zemljopisna dužina bazne stanice 1, odnosno bazne stanice 2,
- $lat_{1,2}$ – zemljopisna širina bazne stanice 1, odnosno bazne stanice 2.

Rezultat su vrijednosti koje se pohranjuju u odgovarajuću tablicu `TABLICA_UDALJENOSTI`, a koja sadrži sljedeća polja, kako je prikazano u tablici 11.

- `ID_PAR` – jedinstveni identifikator svakog para baznih stanica formiran kao `ID(LOKACIJA1)_ID(LOKACIJA2)`. Primjer: ukoliko se mjeri udaljenost između lokacije 3 i lokacije 7, njihov `ID_PAR` će biti **3_7**. Podrazumijeva se da je udaljenost između dvije lokacije ista, bez obzira na smjer putovanja, odnosno udaljenost između baznih stanica 3_7 i 7_3 mora biti jednaka.
- `ID_LOKACIJA_1`,
- `ID_LOKACIJA_2`,
- `PRAV_UDALJ (km)` - rezultat Haversinove formule za svaki `ID_PAR` u jedinici kilometar.

Tablica 11. Tablica udaljenosti između baznih stanica (primjer)

ID_PAR	ID_LOKACIJE1	ID_LOKACIJE_2	PRAV_UDALJ
1_2	1	2	2,3
1_3	1	3	2,9
1_4	1	4	1,8
2_3	2	3	4,5

3.2.3. Podskupovi podataka

3.2.3.1. Kreiranje podskupova podataka

U algoritmu označeno kao korak 3.1. U ovisnosti o svrsi i namjeni analize, moguće je definirati različite vremenske okvire unutar jednog dana. Za potrebe procjene mobilnosti, podaci za jedan dan (24h) dijele se na osam jednakih vremenskih okvira O1-O8 u trajanju od 180 minuta.

Vremenski okviri su:

- a) O1 : 00:00:00 – 02:59:59,
- b) O2 : 03:00:00 - 05:59:59,
- c) O3 : 06:00:00 - 08:59:59,
- d) O4 : 09:00:00 - 11:59:59,
- e) O5 : 12:00:00 - 14:59:59,
- f) O6 : 15:00:00 - 17:59:59,
- g) O7 : 18:00:00 - 20:59:59,
- h) O8 : 21:00:00 - 23:59:59.

3.2.4. Identifikacija putovanja

U hodogramu je označeno kao korak 4.1. Cilj ovog koraka jest identificirati sve zapise promjene lokacije za svako putovanje, za svakog korisnika, u svakom pojedinom setu podataka [85], te izračunati vrijednosti koje će biti pohranjene u tablicu koja će sadržavati sljedeće kolone, a primjer koje je dan u tablici 12:

- a) KORISNIK_ID – jedinstveni identifikator za svakog pojedinog korisnika,

- b) PUTOVANJE_ID – jedinstveni identifikator za svako pojedino putovanje,
- c) VRIJEME (t) – vremenska oznaka u kojoj je aktivnost zabilježena,
- d) Trajanje putovanja – definirano kao razlika vremena između promjene stanja (Δt),
- e) ID_LOKACIJE_1 – položaj izvorišne bazne stanice (engl. *Origin*),
ID_LOKACIJE_2 – položaj odredišne bazne stanice (engl. *Destination*).

Tablica 12. Tablica putovanja (primjer)

KORISNIK_ID	PUTOVANJE_ID	t	Δt	ID_LOKACIJE_1	ID_LOKACIJE_2
49892		07:52:26			
49892	1	08:02:21	0:09:55	1	5
49892	2	08:32:26	0:30:05	1	7
49892	3	08:32:50	0:00:24	7	8

U ovom se koraku računa pokazatelj B – trajanje putovanja definira se kao razlika u vremenu između zabilježenog početka aktivnosti na izvorišnoj i zabilježenog početka aktivnosti na odredišnoj čeliji za svako pojedino putovanje. Računa se pomoću relacije (7):

$$B = \Delta t(i, j) = t(i)_{dest} - t(i)_{orig} \quad (7)$$

pri čemu je:

- B – pokazatelj trajanja putovanja po svakom pojedinom putovanju,
- $t(i)_{orig}$ – vremenska oznaka u kojoj je zabilježena aktivnost korisnika na baznoj stanici koja je identificirana kao početak putovanja (engl. *origin*),
- $t(i)_{dest}$ – vremenska oznaka u kojoj je zabilježena aktivnost korisnika na baznoj stanici koja je identificirana kao kraj putovanja (engl. *destination*),
- $\Delta t(i, j)$ – trajanje putovanja između dvije bazne stanice.

3.2.5. Spajanje tablica i uklanjanje suvišnih podataka

3.2.5.1. Uklanjanje ID korisnika

U algoritmu označeno kao korak 5.1. U daljnjim koracima podatak KORISNIK_ID nije potreban te se može izostaviti, pri čemu je rezultat skup podataka prikazan kao u tablici 13.

Tablica 13. Tablica putovanja bez identiteta korisnika (primjer)

PUTOVANJE_ID	T	Δt	ID_LOKACIJE_1	ID_LOKACIJE_2
	07:52:26			
1	08:02:21	0:09:55	1	5
2	08:32:26	0:30:05	1	7
3	08:32:50	0:00:24	7	8

3.2.5.2. Dodjeljivanje udaljenosti svakom paru baznih stanica

U algoritmu označeno kao korak 5.2. U ovom se koraku vrijednostima iz tablice TABLICA_UDALJENOSTI na osnovi podataka o ID_LOKACIJE_1 i ID_LOKACIJE_2 pridijeljuju podaci ID_PAR i PRAV_UDALJ. Rezultat tog postupka su vrijednosti putovanja s pridijeljenim udaljenostima između parova baznih stanica, a kako je prikazano u tablici 14.

Tablica 14. Identificirana putovanja sa pridijeljenim udaljenostima između parova baznih stanica (primjer)

PUTOVANJE_ID	T	Δt	ID_LOKACIJE_1	ID_LOKACIJE_2	ID_PAR	PRAV_UDALJ
	07:52:26					
1	08:02:21	0:09:55	1	5	1_5	2,9
2	08:32:26	0:30:05	1	7	1_7	1,8
3	08:32:50	0:00:24	7	8	7_8	0,5

3.2.5.3. Izračun brzina putovanja

U algoritmu označeno kao korak 5.3. U ovom koraku izračunava se izračun brzina putovanja (PRAV_BRZ) za svako pojedino putovanje kao količnik vrijednosti PRAV_UDALJ i Δt . Računa se u jedinici km/h. Preduvjet je da se Δt pretvori u jedinicu sat. Cilj proračuna

brzine kretanja jest identifikacija putovanja u kojima brzine nisu realne za gradsko okruženje te stoga ukazuju na pogrešku, nakon čega slijedi njihovo uklanjanje iz skupa podataka. Rezultat su vrijednosti brzina za svako pojedino putovanje, kako je prikazano u tablici 15.

Tablica 15. Tablica brzina za svako pojedino putovanje (primjer)

PUTOVANJE_ID	T	Δt	ID_LOKACIJE_1	ID_LOKACIJE_2	ID_PAR	PRAV_UDALJ	PRAV_BRZ
1	08:02:21	0:09:55	1	5	1_5	2,9	19
2	08:32:26	0:30:05	1	7	1_7	1,8	21

Slijedi izračun vrijednosti pokazatelja D1 pomoću relacije (8).

$$D1(i, j) = \frac{C(i, j)}{B(i, j)} \quad (8)$$

pri čemu je:

- $D1(i, j)$ - brzina kretanja po svakom pojedinom putovanju u vremenskom okviru,
- $C(i, j)$ - euklidska udaljenost između parova baznih stanica,
- $B(i, j)$ - trajanje putovanja po svakom pojedinom putovanju u vremenskom okviru.

3.2.5.4. *Filtriranje podataka*

U algoritmu označeno kao korak 5.4. U ovom se koraku odvija filtriranje podataka sukladno definiranim kriterijima:

- Filtriranje podataka u kojima je vremenska razlika između dva zabilježena događaja manja od definiranog vremenskog praga. Filtriraju se sva putovanja koja su kraća od 10 minuta, odnosno ona koja su duža od 60 minuta [61], [70], [85].

- b. Filtriranje podataka u kojima je pravocrtna prostorna udaljenost između baznih stanica manja od definiranog prostornog praga. Prostorni prag je definiran kao 1 km [61], [70], [85].
- c. Filtriranje podataka u kojim izračunata brzina putovanja nije realna za urbane migracije. Filtriraju se sva putovanja u kojima je brzina veća od 100 km/h.
- d. Filtriranje redaka u kojima ne postoji vrijednost za PUTOVANJE_ID.

Primjer uklanjanja podataka filtriranjem dan je u tablici 16.

Tablica 16. Identificiranje i filtriranje zapisa koji ne odgovaraju vremenskim i prostornim pretpostavkama (primjer)

PUTOVANJE_ID	T	Δt	ID_LOKACIJE_1	ID_LOKACIJE_2	ID_PARR	PRAV_UDALJ
	07:52:26					
1	08:02:21	0:09:55	1	5	1_5	2,9
2	08:32:26	0:30:05	1	7	1_7	1,8
3	08:32:50	0:00:24	7	8	7_8	0,5

Primjer: zapis u retku 3 se u ovom koraku filtrira (odbacuje) jer ne zadovoljava vremenske (razmak minimalno 10 minuta i najviše 60 minuta) niti prostorne (pravocrtna udaljenost lokacije manje od 1 km) preduvjete. Također, uklanja se i prvi zapis u tablici jer ne sadrži informacije o putovanjima.

Potom, u ovom se koraku uklanjaju sva putovanja za koje se utvrdi da izračunata brzina putovanja nije realna. Uklanjaju se sve vrijednosti brzina većih od opisanih, a primjer je dan u tablici 17.

Tablica 17. Uklanjanje putovanja koji ne zadovoljavaju uvjete vezane za brzinu (primjer)

PUTOVANJE_ID	T	Δt	ID_LOKACIJE_1	ID_LOKACIJE_2	ID_PARR	PRAV_UDALJ	PRAV_BRZ
34	08:02:21	0:09:55	1	5	1_5	2,9	19
35	----	----	----	----	----	----	215

Primjerice, putovanje pod rednim brojem 35 je uklonjeno iz baze jer ukazuje da se korisnik kretao prosječnom brzinom od 215 km/h, što nije realno unutar prometnog sustava urbane aglomeracije.

3.2.5.5. *Kalibracijski i validacijski skup podataka*

U algoritmu je označeno kao korak 5.5. Skup podataka dijeli na dva skupa i to na skup za kalibraciju i skup za validaciju modela. Skup za kalibraciju sastoji se od 80 % ukupnog skupa podataka, a skup za validaciju sastoji se od preostalih 20 % ukupnog skupa podataka. Skup se dijeli na način da se iz ukupnog skupa podataka, koji sadrži popis svih putovanja, identificira svaki peti zapis. Svaki peti zapis se uklanja iz osnovnog skupa podataka i pohranjuje se u novi skup podataka za validaciju. Skup za kalibraciju tada postaje originalni skup podataka kojem je uklonjeno svako peto putovanje, dok skup za validaciju postaje onaj skup podataka koji uključuje samo putovanja koja su uklonjena iz skupa za kalibraciju. Svi daljnji koraci provode se na oba seta podataka za svaki vremenski okvir.

3.2.6. Izračun vrijednosti pokazatelja

U algoritmu označeno kao korak 6. Rezultat ovog koraka jest izračun vrijednosti pokazatelja za svaki vremenski okvir, te pohrana podataka u tri različite matrice za svaki vremenski okvir. Prva je matrica putovanja (O-D matrica), druga je matrica udaljenosti i treća je matrica vremena.

3.2.6.1. *Matrica putovanja (O-D matrica)*

U algoritmu označeno kao korak 6.1. Matrica putovanja sadrži sumu svih putovanja (prebrojavanje Putovanje_ID) između pojedinih parova baznih stanica unutar odgovarajućeg vremenskog razdoblja. Računa se pomoću formule (9), a prikazana je u tablici 18.

Tablica 18. Primjer matrice putovanja (O-D matrica) prikazane u tabličnom obliku (primjer)

ID LOKACIJE 1	ID LOKACIJE 2	ID PAR	UKUPAN BROJ PUTOVANJA
1	5	1_5	458
1	7	1_7	782

Pokazatelj broja putovanja između pojedinih parova baznih stanica $A(i,j)$ računa se korištenjem relacije (9):

$$A(i,j) = \sum_{i=0}^n Putovanje_ID(i,j) \quad (9)$$

pri čemu je:

- $A(i,j)$ – ukupan broj zabilježenih (registriranih) putovanja između pojedinih parova baznih stanica (matrica putovanja),
- $Putovanje_ID(i,j)$ – putovanje između dvije bazne stanice u odgovarajućem vremenskom okviru, pri čemu su zadovoljene sve pretpostavke.

3.2.6.2. Matrica udaljenost

U algoritmu označeno kao korak 6.2. Ova matrica sadrži vrijednosti udaljenosti između svih parova baznih stanica između kojih je generirano putovanje unutar odgovarajućeg vremenskog razdoblja.

Tablica 19. Vrijednosti pokazatelja udaljenosti prikazani u tabličnom obliku (primjer)

ID PAR	PRAV UDALJ
1_5	1,8
1_7	4,2

Vrijednosti pokazatelja udaljenosti između parova baznih stanica definirana je u koraku algoritma 5.2.

3.2.6.3. Matrica vremena

U algoritmu označeno kao korak 6.3. Ova matrica sadrži vrijednosti srednjeg trajanja putovanja između svih parova baznih stanica za odgovarajuće vremensko razdoblje, koji se izračunavaju sukladno metodologiji opisanoj u koraku algoritma 4.1.

Pokazatelj \bar{B} računa se pomoću izraza (10):

$$\bar{B}(i, j) = \frac{\sum_{i=0}^n B(i, j)}{n} \quad (10)$$

kao srednja vrijednost svih trajanja putovanja između para baznih stanica unutar odgovarajućeg vremenskog razdoblja.

pri čemu je:

- $\bar{B}_{i,j}$ – srednja vrijednost svih trajanja putovanja između pojedinog para baznih stanica u vremenskom okviru,
- $B(i, j)$ – vrijednost trajanja putovanja po svakom pojedinom putovanju u vremenskom okviru,
- n – broj registriranih putovanja između pojedinog para baznih stanica u vremenskom okviru.

Tablica 20. Primjer tablice vremena putovanja (primjer)

ID_PAR	SREDNJE_TRAJANJE (h)
1_5	0,2
1_7	0,12

Vrijednosti pokazatelja vremena putovanja mogu biti prikazani i u obliku matrice (primjer):

$$\begin{bmatrix} - & 0,18 & 0,4 \\ 1,8 & - & 7 \\ 0,34 & 0,7 & - \end{bmatrix}$$

Vrijednosti pokazatelja udaljenosti između parova baznih stanica definirana je u koraku algoritma 5.2. **Također, važno je napomenuti da je euklidska udaljenost između parova baznih stanica ista bez obzira o kojem se smjeru kretanja radi.** Po završetku ovog koraka definirane su vrijednosti svih pokazatelja potrebnih za proračun indeksa urbane mobilnosti, koji se potom izračunava u koracima algoritma 7, 8 i 9.

3.2.6.4. *Normalizacija podataka*

U algoritmu označeno kao korak 6.4. Rezultat prethodnog koraka su vrijednosti pohranjene u tri matrice za svako vremensko razdoblje; i to u matricu broja putovanja, matricu trajanja putovanja i matricu udaljenosti. Obzirom da se dan dijeli u osam vremenskih razdoblja, ukupan izlaz iz prethodnog koraka uključuje ukupno 24 matrice (8 x 3), koje se potom koriste za proračun indeksa urbane mobilnosti. Kako bi se osiguralo da je model primjenjiv na sva urbana područja, bez obzira na njihovu veličinu, potrebno je dobivene podatke normalizirati, odnosno podatke u njima svesti u interval [0,1]. Normalizacija se izvodi tako da se vrijednost pokazatelja u određenom vremenskom intervalu normalizira s najvećom vrijednošću pojedinog pokazatelja za svih osam vremenskih intervala. Svrha normizacije provedene na ovaj način jest uključiti u izračun i podatak u kolikoj mjeri pojedini pokazatelj sudjeluje u ukupnoj mobilnosti urbane aglomeracije u svakom pojedinom okviru, odnosno identificirati njegov maksimum. Ovo će rezultirati vjerodostojnijim izračunom indeksa urbane mobilnosti za svaki vremenski okvir.

3.2.6.5. *Normalizacija broja putovanja*

U algoritmu označeno kao korak 6.5. Normalizacija broja putovanja računa se na način da se identificira najveća vrijednost pokazatelja broja putovanja za pojedini par izvora i odredišta unutar svih osam vremenskih razdoblja (11), koja se potom pohranjuje u novu matricu, a koja nosi naziv matrica najbrojnijih količina putovanja:

$$\max A_{(i,j)} = \max(A_{i,j}), A_{i,j} \in (O1 - O8) \quad (11)$$

pri čemu je:

- $maxA_{(i,j)}$ – najveća vrijednost broja putovanja za odgovarajući par baznih stanica za sve vremenske okvire unutar jednog dana,
- $A(i,j)$ – ukupan broj zabilježenih (registriranih) putovanja između pojedinih parova baznih stanica (matrica putovanja).

Nakon toga slijedi izračun normalizirane vrijednosti količine putovanja koji se računa na način da se vrijednosti pokazatelja u osam matrica za svako pojedino razdoblje podijele s vrijednošću matrice najvećih količina putovanja, te se tako dobivaju normalizirane matrice putovanja za svako vremensko razdoblje (12):

$$norA_{(i,j)} = \frac{A_{i,j}}{max(A_{i,j})}, A_{i,j} \in (01 - 08) \quad (12)$$

pri čemu je:

- $norA_{(i,j)}$ – normalizirana vrijednost broja putovanja za odgovarajući par baznih stanica za sve vremenske okvire unutar jednog dana,
- $maxA_{(i,j)}$ – najveća vrijednost broja putovanja za odgovarajući par baznih stanica za sve vremenske okvire unutar jednog dana,
- $A(i,j)$ – ukupan broj zabilježenih (registriranih) putovanja između pojedinih parova baznih stanica (matrica putovanja).

3.2.6.6. Normalizacija trajanja putovanja

U algoritmu označeno kao korak 6.6. Normalizacija pokazatelja trajanja putovanja računa se na način da se identificira najveća vrijednost pokazatelja trajanja putovanja za pojedini par izvora i odredišta unutar svih osam vremenskih razdoblja (13), koja se potom pohranjuje u novu matricu, a koja nosi naziv matrica najvećih trajanja putovanja:

$$\max \overline{B_{i,j}} = \max(\overline{B_{i,j}}), \overline{B_{i,j}} \in (01 - 08) \quad (13)$$

pri čemu je:

- $\overline{B_{i,j}}$ – srednja vrijednost svih trajanja putovanja između pojedinog para baznih stanica u vremenskom okviru,
- $\max(\overline{B_{i,j}})$ – najveća vrijednost srednje brzine putovanja za odgovarajući par baznih stanica za sve vremenske okvire unutar jednog dana.

Nakon toga slijedi izračun normalizirane vrijednosti trajanja putovanja koji se računa na način da se vrijednosti pokazatelja u osam matrica za svako pojedino razdoblje podijele s vrijednošću matrice najvećih količina putovanja, te se tako dobivaju normalizirane matrice putovanja za svako vremensko razdoblje (14):

$$norB_{(i,j)} = \frac{\overline{B_{i,j}}}{\max(B_{i,j})}, A_{i,j} \in (01 - 08) \quad (14)$$

pri čemu je:

- $norB_{(i,j)}$ – normalizirana vrijednost srednje vrijednosti trajanja putovanja za odgovarajući par baznih stanica za sve vremenske okvire unutar jednog dana,
- $\max B_{(i,j)}$ – najveća vrijednost trajanja putovanja za odgovarajući par baznih stanica za sve vremenske okvire unutar jednog dana,
- $\overline{B_{i,j}}$ – srednja vrijednost svih trajanja putovanja između pojedinog para baznih stanica u vremenskom okviru.

3.2.6.7. Normalizacija udaljenosti

U algoritmu označeno kao korak 6.7. Vrijednost pokazatelja udaljenosti se za razliku od prethodno opisana dva pokazatelja ne mijenja u vremenu, jer je riječ o fizikalnoj veličini koja je konstantna i predstavlja euklidsku udaljenost između parova baznih stanica. Stoga se normalizacija računa na način da se dužina pojedine dionice između parova izvora i odredišta normalizira s dužinom ukupne mreže, odnosno s ukupnom dužinom svih dionica na kojima je ostvareno putovanje u svim vremenskim okvirima (15):

$$norC_{(i,j)} = \frac{C_{i,j}}{\sum_{i=1}^n C_{i,j}} \quad (15)$$

pri čemu je:

- $norC_{(i,j)}$ – normalizirana vrijednost pokazatelja udaljenosti za odgovarajući par baznih stanica,
- $C(i,j)$ – euklidska udaljenost između parova baznih stanica za sve dionice na kojima je ostvareno putovanje.

Normalizirane vrijednosti se potom pohranjuju u tablicu normalizirane vrijednosti udaljenosti te se potom koriste za daljnje izračunavanje indeksa urbane mobilnosti. Primjer vrijednosti pokazatelja tijekom odvijanja procesa normalizacije dâan je na slikama u nastavku. Primjer simuliranih podataka koji su izlaz iz algoritma, kao tablice broja putovanja, tablice udaljenosti i tablice trajanja putovanja za tri vremenska intervala O1 do O3, prikazan je na slici 11. Iz tih podataka identificira se matrica najbrojnijih putovanja (slika 12.), pomoću koje se potom računaju normalizirane matrice putovanja (slika 13.).

Slijedi izračun matrice najdužih putovanja (slika 14.), potom izračun normalizirane matrice najdužih putovanja (slika 14.) te izračun normalizirane matrice udaljenosti (slika 15.). Za potrebe ilustracije postupka, polja matrice (izvori i odredišta putovanja) označena su oznakama A, B, C i D.

O1						O2						O3						
Broj putovanja (n)						Broj putovanja (n)						Broj putovanja (n)						
	A	B	C	D	E		A	B	C	D	E		A	B	C	D	E	
A			88	49	77	45	A		48	79	61	144	A		785	106	1133	303
B	18			58	80	6	B	68		34	83	91	B	199		523	1332	969
C	90	27		67	90	27	C	81	141		81	141	C	794	1060		1306	527
D	58	80	6		78	18	D	34	83	91		68	D	871	299	572		897
E	88	49	77	45			E	48	79	61	144		E	785	106	1133	303	

Udaljenost (km)						Udaljenost (km)						Udaljenost (km)						
	A	B	C	D	E		A	B	C	D	E		A	B	C	D	E	
A			3	5	3	12	A		3	5	3	12	A		3	5	3	12
B	1			8	4	2	B	1		8	4	2	B	1		8	4	2
C	2	4			2	4	C	2	4		2	4	C	2	4		2	4
D	8	4	2			1	D	8	4	2		1	D	8	4	2		1
E	3	5	3	12			E	3	5	3	12		E	3	5	3	12	

Trajanje putovanja (h)						Trajanje putovanja (h)						Trajanje putovanja (h)						
	A	B	C	D	E		A	B	C	D	E		A	B	C	D	E	
A			0,1	0,2	0,1	0,4	A		0,2	0,4	0,1	0,3	A		0,52	0,52	0,26	1
B	0,1			0,2	0,1	0,25	B	0		0,1	0,2	0,2	B	0,3		0,39	0,26	2
C	0,05	0,25			0,05	0,25	C	0	0,2		0,2	0,2	C	0,7	0,65		0,7	0,7
D	0,15	0,1	0,3			0,1	D	0	0,2	0,2		0,2	D	0,4	0,26	1,95		0,3
E	0,1	0,2	0,1	0,4			E	0	0,4	0,1	0,27		E	0,5	0,52	0,26	1,04	

Slika 11. Primjer simuliranih podataka koji su izlaz iz algoritma, kao tablice broja putovanja, tablice udaljenosti i tablice trajanja putovanja za tri vremenska intervala O1 do O3

Matrica najvećih putovanja					
	A	B	C	D	E
A		785	433	1225	625
B	297		871	1332	969
C	794	1060		1306	1060
D	871	437	646		897
E	785	433	1225	625	

Slika 12. Primjer matrice najbrojnijih putovanja

O1						O2						O3						
Norm. matrica putovanja						Norm. matrica putovanja						Norm. matrica putovanja						
	A	B	C	D	E		A	B	C	D	E		A	B	C	D	E	
A			0,11	0,11	0,06	0,07	A	140	0,1	0,18	0,05	0,2	A		1	0,2	0,9	0,5
B	0,06			0,07	0,06	0,01	B	0,23	67	0,04	0,06	0,1	B	0,7	973	0,6	1	1
C	0,11	0,03			0,07	0,03	C	0,10	0,13	111	0,06	0,1	C	1	1	###	1	0,5
D	0,07	0,18	0,01			0,02	D	0,04	0,19	0,14	37	0,1	D	1	0,7	0,9	189	1
E	0,11	0,11	0,06	0,07			E	0,06	0,18	0,05	0,23	95	E	1	0,2	0,9	0,5	189

Slika 13. Primjer normalizirane matrice putovanja

Matrica najdužih putovanja

	A	B	C	D	E
A			0,52	0,52	0,26
B	0,26			0,4	0,26
C	0,7	0,65		0,7	0,65
D	0,39	0,26	1,95		0,5
E	0,52	0,52	0,26	1,04	

Slika 14. Izračun matrice najdužih putovanja

Trajanje putovanja						Trajanje putovanja						Trajanje putovanja					
	A	B	C	D	E		A	B	C	D	E		A	B	C	D	E
A		0,19	0,38	0,38	0,38	A		0,3	0,77	0,38	0,3	A		1	1	1	1
B	0,38		0,38	0,38	0,13	B	0,77		0,25	0,77	0,1	B	1		1	1	1
C	0,07	0,38		0,07	0,38	C	0,29	0,3		0,29	0,3	C	1	1		1	1
D	0,38	0,38	0,13		0,2	D	0,26	0,8	0,09		0,4	D	1	1	1		0,5
E	0,19	0,38	0,38	0,38		E	0,29	0,8	0,38	0,26		E	1	1	1	1	

Slika 15. Izračun normalizirane matrice trajanja putovanja

Cjelokupna mreža						Normizirana mreža						
	A	B	C	D	E		A	B	C	D	E	
A			3	5	3	12	A		0,1	0,11	0,07	0,3
B	3			8	4	2	B	0,1		0,18	0,09	0
C	5	8			2	4	C	0,1	0,2		0,05	0,1
D	3	4	2			1	D	0,1	0,1	0,05		0
E	12	2	4	1			E	0,3	0	0,09	0,02	

Ukupna dužina cjelokupne mreže 44

Slika 16. Primjer cjelokupne mreže, ukupne dužine cjelokupne mreže i normaliziranih veličina

3.2.7. Izračun parcijalnog indeksa urbane mobilnosti $pIM_{i,j}$

U algoritmu označeno kao korak 7. Izračun vrijednosti veličine $pIM_{i,j}$ – parcijalni indeks urbane mobilnosti za odgovarajući par baznih stanica u odgovarajućem vremenskom okviru izračunava se pomoću modela koji je definiran u sljedećim poglavljima. Stoga, parcijalni indeks urbane mobilnosti definira se kao funkcija normalizirane vrijednosti pokazatelja, i to ukupnog broja zabilježenih putovanja između pojedinih parova baznih stanica, zatim srednje vrijednosti trajanja putovanja između pojedinih parova baznih stanica u odgovarajućem vremenskom okviru te euklidske udaljenosti između parova baznih stanica, a kako je prikazano u izrazu (16). Rezultat je veličina u intervalu $[0,1]$ koja označava vrijednost procjene

mobilnosti, pri čemu nulta vrijednost označava najnižu mobilnosti, a vrijednost 1 označava najveću razinu mobilnosti:

$$pIM_{i,j} = f((normA(i,j), norm\overline{B}_{i,j}, normC(i,j))) \quad (16)$$

- $normA_{(i,j)}$ – normalizirana vrijednost broja putovanja za odgovarajući par baznih stanica za sve vremenske okvire unutar jednog dana,
- $norm\overline{B}_{i,j}$ – normalizirana vrijednost srednje vrijednosti trajanja putovanja za odgovarajući par baznih stanica za sve vremenske okvire unutar jednog dana,
- $normC_{(i,j)}$ – normalizirana vrijednost pokazatelja udaljenosti za odgovarajući par baznih stanica.

Obzirom da će model biti definiran u poglavlju 0, implementacija simuliranih podataka korištenih za ilustraciju postupka nastaviti će se u poglavlju 0.

3.2.8. Izračun indeksa urbane mobilnosti

U algoritmu označeno kao korak 8. U ovom koraku računa se indeks urbane mobilnosti (IM) za svaki vremenski okvir. Računa se kao srednja vrijednost parcijalnih indeksa urbane mobilnosti između svakog para baznih stanica (urbanih područja) između kojih je ostvareno putovanje u odgovarajućem vremenskom okviru (O). Indeks urbane mobilnosti može imati vrijednost od 0 do 1, odnosno može se prikazati kao postotak s vrijednošću od 0 do 100 %. Izračunava se pomoću formule (17). IM se izračunava za svaki vremenski okvir:

$$IM = \sum_{i=1}^n \frac{pIM_{(i,j)}}{n} [\%] \quad (17)$$

pri čemu je:

- IM – indeks urbane mobilnosti za vremenski okvir,
- $pIM_{i,j}$ – parcijalni indeks urbane mobilnosti za odgovarajući par baznih stanica u odgovarajućem vremenskom okviru,
- n – ukupan broj parova izvora i odredišta za koje je izvršena procjena mobilnosti.

3.2.9. Definiranje i izračun koeficijenta udjela u ukupnoj mobilnosti

U algoritmu označeno kao korak 9. Po izračunu parcijalnog indeksa urbane mobilnosti moguće je izračunati i dodatni pokazatelj koji pruža širu sliku o procjeni urbane mobilnosti, kao dodatni element parcijalnom indeksu mobilnosti. Dodatni pokazatelj nosi naziv koeficijent **udjela u ukupnoj mobilnosti** ($\alpha_{i,j}$). Za svaki par baznih stanica definirani su pokazatelji broj putovanja i euklidska udaljenost između njih. Ukupna mobilnost može se definirati kao umnožak broja putovanja i udaljenosti između pojedinih parova baznih stanica. Jedinica za ovu veličinu jest putnički/prijevozni kilometar (pkm). Ova jedinica je u prometnom inženjerstvu uvriježena kao mjera količine kretanja ili kao mjera prometnog rada. Kada se jedan putnik preveze ili prijeđe udaljenost od 10 km, ostvareno je 10 pkm ($1 \times 10 = 10$). Ako tri putnika prijeđu udaljenost od 10 km, ostvareno je 30 pkm ($3 \times 10 = 30$). Izračun putničkih kilometara temelji se na stvarno prevezenim putnicima i stvarno prijeđenoj udaljenosti [19], [33], [34]. Koeficijent $\alpha_{i,j}$ izračunava se izrazom (18):

$$\alpha_{(i,j)} = \frac{A_{(i,j)} * C_{(i,j)}}{\sum_{i=0}^n (A_{(i,j)} * C_{(i,j)})}$$

pri čemu je:

- $\alpha_{i,j}$ – koeficijent udjela u ukupnoj mobilnosti za svaki par izvora i odredišta (par baznih stanica),
- $A_{(i,j)}$ – vrijednost broja okvir unutar jednog dana,
- $C_{(i,j)}$ – za vrijednost pokazatelja udaljenosti za odgovarajući par baznih stanica.

Dakle, množenjem vrijednosti pokazatelja broja putovanja i udaljenosti, moguće je izračunati ukupnu mobilnosti koju definiramo kao zbroj svih umnožaka vrijednosti pokazatelja broja putovanja i prijeđene udaljenosti za svaki par baznih stanica unutar vremenskog okvira. Zbroj svih vrijednosti ukupne mobilnosti svih vremenskih okvira daje ukupnu mobilnost u jednom danu. Ukupna količina mobilnosti na razini cijele urbane aglomeracije za odgovarajući vremenski okvir, kao zbroj svih količina mobilnosti, računa se putem formule (19):

$$Uk_mob = \sum_{i=0}^n (A_{(i,j)} * C_{(i,j)}) \quad (19)$$

Na slici 16. prikazan je primjer vrijednosti pokazatelja broja putovanja za tri vremenska okvira. Umnoškom vrijednosti u pojedinom polju matrice i udaljenosti između tih parova baznih stanica (slika 17.) dobiva se ukupna mobilnost za pojedini vremenski okvir (slika 18.). Zbroj svih vrijednosti unutar matrice predstavlja ukupnu mobilnost u vremenskom intervalu. Vrijednost ukupne mobilnosti između pojedinih parova baznih stanica (urbanih područja) tada se relativizira u odnosu na vrijednost ukupne mobilnosti za taj vremenski okvir. Rezultat je postotak koji govori koliko pojedini par baznih stanica sudjeluje u ukupnoj mobilnosti u odgovarajućem vremenskom razdoblju.

Ukupna mobilnost O1						Ukupna mobilnost O1						Ukupna mobilnost O2						
	A	B	C	D	E		A	B	C	D	E		A	B	C	D	E	
A			264	245	231	540	A		144	395	183	1728	A		2355	530	3399	3636
B	18			464	320	12	B	68		272	332	182	B	199		4184	5328	1938
C	180	108			180	108	C	162	564		162	564	C	1588	4240		2612	2108
D	464	320	12			18	D	272	332	182		68	D	6968	1196	1144		897
E	264	245	231	540			E	144	395	183	1728		E	2355	530	3399	3636	
Ukupna mobilnost O1 4764						Ukupna mobilnost O2 8060						Ukupna mobilnost O3 52.242						

Slika 17. Izračun ukupne mobilnosti

Udio u ukupnoj mobilnosti					
	A	B	C	D	E
A		6%	5%	5%	11%
B	0%		10%	7%	0%
C	4%	2%		4%	2%
D	10%	7%	0%		0%
E	6%	5%	5%	11%	

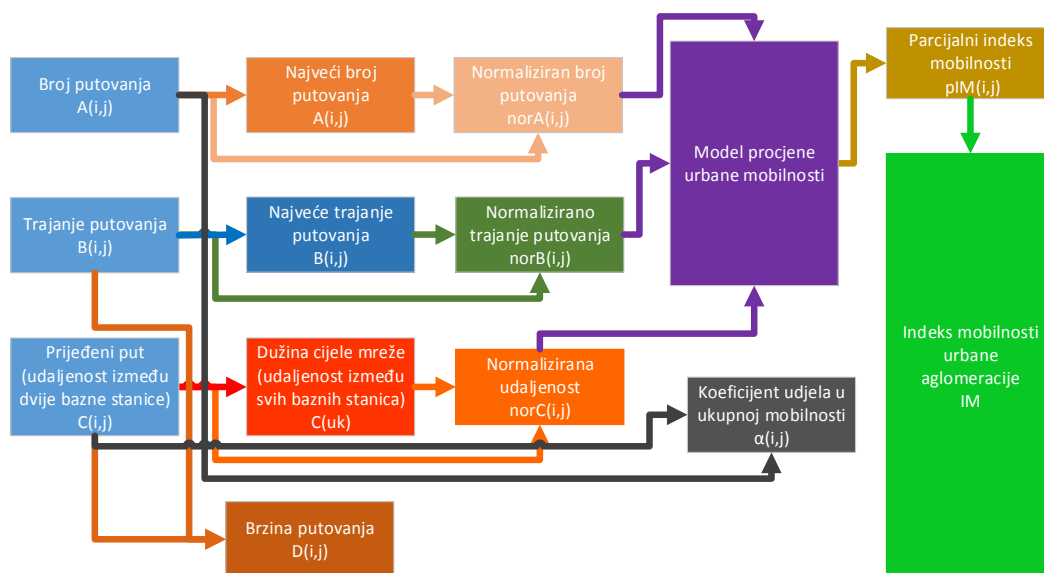
Udio u ukupnoj mobilnosti					
	A	B	C	D	E
A		2%	5%	2%	21%
B	1%		3%	4%	2%
C	2%	7%		2%	7%
D	3%	4%	2%		1%
E	2%	5%	2%	21%	

Udio u ukupnoj mobilnosti					
	A	B	C	D	E
A		5%	1%	7%	7%
B	0%		8%	10%	4%
C	3%	8%		5%	4%
D	13%	2%	2%		2%
E	5%	1%	7%	7%	

Slika 18. Izračun udjela u ukupnoj mobilnosti

3.2.10. Verifikacija i validacija

U algoritmu označeno kao korak 10. Verifikacija se provodi tijekom nekoliko koraka ovog postupka. Svrha verifikacije u ovom dijelu postupka jest potvrditi da definirani algoritmi i napisana programska podrška pravilno izračunavaju segment za koji su namijenjeni. Verificira se algoritam koji dijeli podskup podataka na vremenske okvire, zatim se verificira algoritam koji izračunava broj putovanja, algoritam koji izračunava trajanje putovanja, kao i algoritam koji izračunava brzinu, odnosno udaljenost. Verifikacija je provedena na način da je iz osnovnog skupa nasumično odabran mali uzorak podataka. Na njemu su ručno provedeni postupci algoritma koje je potrebno verificirati. Potom se rezultati uspoređuju s onima koji su rezultat izvršavanja algoritma. Verifikacija svih algoritama je provedena uspješno, čime je potvrđeno kako svi napisani algoritmi pravilno izvršavaju operacije kojima su namijenjeni. U nastavku je provedena validacija predloženog modela procjene indeksa urbane mobilnosti. Po izračunu pokazatelja izdvaja se skup od 20 % podataka za svaki vremenski okvir te se temeljem njih izračunavaju parcijalni indeksi i indeks urbane mobilnosti. Potom se rezultati dobiveni iz tih podataka uspoređuju s rezultatima obrade preostalih podataka iz tog skupa te se utvrđuje odstupanje rezultata. Na taj način se utvrđuje konzistentnost cijelog pristupa. Ilustracija međusobnog odnosa pokazatelja i veličina u procesu izračuna indeksa urbane mobilnosti prikazana je na slici 19.



Slika 19. Međusobni odnos pokazatelja i veličina u procesu izračuna indeksa urbane mobilnosti

3.3. Utvrđivanje odnosa pokazatelja mobilnosti i procjene indeksa urbane mobilnosti

3.3.1. Anketa

Metoda anketiranja je postupak kojim se na temelju anketnog upitnika istražuju i prikupljaju podaci o predmetu istraživanja. U užem smislu, anketa označava onaj postupak tijekom kojeg se odabranim ispitanicima, odnosno respondentima, usmeno ili pismeno postavljaju određena pitanja, na koja oni također usmeno ili pismeno daju odgovore. Prikupljeni odgovori potom se podvrgavaju različitim vrstama kvantitativne, kvalitativne ili kauzalne analize [38]. Kod priprema znanstvenog istraživanja pomoću metode anketiranja, potrebno je odrediti svrhu i ciljeve istraživanja čije ostvarenje dovodi do dokazivanja postavljene hipoteze. Svrha i ciljevi trebaju biti realno postavljeni [38]. Pitanja u anketi mogu biti otvorena i zatvorena, pri čemu zatvorena mogu biti s ponuđenim odgovorima nabiranja, odnosno s ponuđenim odgovorima intenziteta [38]. U praktičnoj primjeni pitanja anketnih upitnika koriste se različite ljestvice i metode, kao što je ljestvica Likertovog tipa. Izborom pitanja sastavljenih prema toj ljestvici i metodi, moguće je osigurati valjano, precizno i objektivno mjerenje rezultata istraživanja. U ovom radu koristit će se metoda individualnog anketiranja eksperata u području urbane mobilnosti, kao oblik crpljenja znanja u postupku projektiranja ekspertnog sustava. Metoda se primjenjuje anketiranjem više eksperata, kojima se ciljevi istraživanja, model ankete i anketna pitanja prezentiraju na radionicama ili putem telekonferencija. Prednost individualnog anketiranja jest da se svakom ekspertu mogu prilagoditi uvod, uputstvo i dodatna objašnjenja, dok pitanja ostaju ista, što u pravilu implicira kvalitetnije odgovore. Nedostaci se očituju u tome što je individualno anketiranje znatno sporije, postupci nisu standardizirani i nije moguće osigurati anonimnost, što u ovom konkretnom slučaju i nije problem (crpljenje znanja eksperta za potrebe projektiranja ekspertnih sustava inače se provodi i metodom direktnog intervjua). Anketni upitnik osmišljen je na način da se kroz skup pitanja prikupi mišljenje eksperata o tome kako i u kojoj mjeri kombinacija vrijednosti pojedinih pokazatelja urbane mobilnosti utječe na mobilnost. Svrha anketiranja jest prikupiti podatke potrebne za definiranje odnosa između vrijednosti pokazatelja urbane mobilnosti i vrijednosti procjene indeksa urbane mobilnosti. Anketni upitnik sadrži pitanja u obliku scenarija koji uključuju vrijednosti pokazatelja urbane mobilnosti, definirane na način da obuhvate karakteristične vrijednosti pokazatelja iz unaprijed definiranih raspona, kao i predloženi postupak za procjenu mobilnosti, koji je temeljen na saznanjima iz znanstvene literature, a kako je definirano u poglavlju 0.

Eksperti će temeljem vlastite prosudbe svakom pitanju pridijeliti odgovarajuću vrijednost korištenjem predloženog postupka za procjenu mobilnosti. **Anketni upitnik odnosi se na scenarije u karakterističnom (radnom) danu, ne uzimajući u obzir dane vikenda, praznika ili blagdana, kao ni mod prijevoza.** Rezultati anketnog istraživanja osigurat će poveznicu između vrijednosti temeljnih pokazatelja iz scenarija i vrijednosti procjene mobilnosti. U uvodnom dijelu ispitanicima je predstavljena svrha i cilj anketnog upitnika, a potom slijedi dio s uputama za ispunjavanje. Predstavljene su pokazatelji koji su uključeni u postupak procjene urbane mobilnosti, a dan je tekstualni opis svake pojedine razine procjene mobilnosti, s tim da u tim opisima nisu korišteni pokazatelji koji su dio anketnog upitnika, kako se na taj način ne bi utjecalo na rezultat. Ispitanicima je potom predstavljen niz od 27 scenarija koji sadrže permutaciju kategoriziranih vrijednosti pokazatelja, na koji onda oni odgovaraju.

3.3.1.1. *Pokazatelji mobilnosti za anketu*

Urbana mobilnost procjenjuje se korištenjem tri pokazatelja dobivenih analizom zapisa za naplatu telekomunikacijskih usluga iz javne pokretne komunikacijske mreže. Pokazatelji su broj putovanja, trajanje putovanja i prijeđeni put (udaljenost). Broj putovanja je pokazatelj koji se odnosi na cjelokupan sustav, odnosno ispitanik procjenjuje mobilnost u kontekstu i temeljem ukupnog broja sudionika koji sudjeluju u mobilnosti u odgovarajućem vremenskom razdoblju. Ostali pokazatelji, pokazatelji trajanja putovanja i pokazatelji prijeđene udaljenosti, odnose se na individualno putovanje, a ispitanik procjenjuje mobilnost promatrajući te vrijednosti iz perspektive krajnjeg korisnika. Detaljan opis pokazatelja je dan u nastavku.

3.3.1.1.1. *Pokazatelj - Broj putovanja*

Pokazatelj broj putovanja odnosi se na broj kretanja između pojedinih urbanih područja (O-D matrica) u odgovarajućem vremenskom okviru. On predstavlja zbroj svih zabilježenih kretanja svih korisnika između pojedinih urbanih područja u odgovarajućem vremenskom okviru.

Vrijednost pokazatelja broja putovanja između para izvora i odredišta u pravilu oscilira u ovisnosti o dobu dana, pri čemu vremenska razdioba putovanja ovisi o nizu faktora. Prometna zagušenja kao nerazmjer između ponude i potražnje, događaju se u jutarnjim i poslijepodnevnim satima i značajka su putovanja u gotovo svim gradovima [26].

Karakteristična vremena za putovanje su odlazak na posao i vraćanje s posla, kada je koncentracija ljudi u prometnom sustavu najveća. Putovanje na posao i s posla predstavlja 15 % ukupnih putovanja. Prema literaturi, putovanja sa svrhom kupovine drugi su značajan čimbenik vremenske distribucije putovanja. Takva putovanja su relativno rijetka u ranojutarnjim satima, a najizraženija su između jutarnjih i poslijepodnevni vršnih opterećenja, te tijekom kasnih poslijepodnevni sati. Društvene aktivnosti te putovanja sa svrhom rekreacije u najvećoj su mjeri rezervirani za poslijepodnevne sate, kada stanovnici urbanih aglomeracija imaju slobodno vrijeme na raspolaganju. Sukladno dnevnoj distribuciji putovanja u urbanim uvjetima, dan je podijeljen u tri kategorije i to: dnevno vršno opterećenje, dnevno izvanvršno opterećenje i noćno opterećenje. Vremenska razdoblja koja pripadaju pojedinim kategorijama prikazana su u tablici 21. Udio pojedinog sata u odnosu na vršno opterećenje prikazano je na slici 20. Razdioba opterećenja po vremenu može se relativizirati tako da se izračuna udio pojedinog sata u odnosu na vršno opterećenje, pri čemu se opterećenje pojedinog sata promatra u odnosu na vršno satno opterećenje u karakterističnom danu, što je također dio tablice 22.

Vrijednost pokazatelja broja putovanja može se relativizirati tako da se izračuna udio putovanja između pojedinih izvora i odredišta u odnosu na najveći zabilježeni broj putovanja između tih izvora i odredišta u karakterističnom danu. Korištenje relativiziranih vrijednosti pokazatelja omogućava korištenje ovog modela u različitim urbanim okruženjima, bez obzira na lokalne specifičnosti, pri čemu prometna opterećenja mogu varirati u odnosu na doba dana.



Slika 20. Udio ukupnih dnevnih putovanja tijekom karakterističnog dana (u %) [26]

Tablica 21. Udio dnevnih putovanja, obrada autora temeljem [26]

Sati u danu	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
Kategorizacija opterećenja	Noćno opterećenje						Dnevno vršno opterećenje			Dnevno izvanvršno opterećenje						Dnevno vršno opterećenje			Dnevno izvanvršno opterećenje			Noćno opterećenje		
Udio u odnosu na vršno opterećenje	7%	4%	4%	7%	11%	18%	32%	91%	55%	32%	32%	41%	44%	48%	50%	59%	100%	73%	68%	64%	27%	23%	14%	7%

Broj putovanja i mobilnost u izravnoj su vezi, tako da je, prema literaturi, broj putovanja vezan za mobilnost na način da, što je broj putovanja veći, veća je i mobilnost [68].

Ispitanicima je u anketnom upitniku pokazatelj broja putovanja definiran na sljedeći način: *pokazatelj broj putovanja odnosi se na broj kretanja između pojedinih urbanih područja u vremenskom okviru. Predstavlja broj svih zabilježenih kretanja svih korisnika između pojedinih urbanih područja u odgovarajućem vremenskom okviru.*

Vrijednost pokazatelja broja putovanja podijeljena je u tri razine, koje su prikazane u tablici 22. Vrijednosti su samo opisne, a za potrebe kasnije statističke analize, svakoj je vrijednosti dodijeljen i numerički reprezentant (zamjenska varijabla).

Tablica 22. Pokazatelj broja putovanja

Broj putovanja	Zamjenska varijabla	Opis
Mali broj putovanja	1	Broj putovanja koji je u urbanim uvjetima u karakterističnom danu uglavnom prisutan u razdobljima kada se u pravilu ne odvijaju putovanja vezana za posao, zabavu, rekreaciju, trgovinu ili društvena zbivanja.
Srednji broj putovanja	2	Broj putovanja koji je u urbanim uvjetima karakterističan za razdoblje izvanvršnog prometnog opterećenja. Odnosi se na broj putovanja, primjerice, tijekom razdoblja kada se odvijaju putovanja motivirana trgovinom, rekreacijom ili društvenim aktivnostima.
Velik broj putovanja	3	Broj putovanja koji je u urbanim uvjetima karakterističan za razdoblja vršnog prometnog opterećenja odnosno za vrijeme razdoblja kada u karakterističnom danu stanovnici tijekom vršnog opterećenja putuju na ili sa posla.

Procjena mobilnosti odvija se po vremenskim okvirima, pri čemu se jedan dan dijeli u vremenske okvire u trajanju od tri sata (180 min) koji nose naziv O1-O8. Vremenski okviri dodatno su podijeljeni u sljedeće kategorije, kako je prikazano u tablici 23., a kako je opisano u poglavlju 3.1.

Tablica 23. Vremenski okviri (doba dana)

Kategorije	Uključeni vremenski okviri	Vremensko razdoblje
Dnevna vršna opterećenja	O3, O6	06:00:00 - 08:59:59 15:00:00 - 17:59:59
Dnevna izvanvršna opterećenja	O4, O5, O7	09:00:00 - 11:59:59 12:00:00 - 14:59:59 18:00:00 - 20:59:59
Noć	O1, O2, O8	21:00:00 – 05:59:59

Također, ukoliko je vrijednost pokazatelja broja putovanja jednaka nuli, odnosno između izvora i odredišta nije zabilježeno niti jedno putovanje, mobilnosti nije bilo, tako da je mobilnost jednaka nuli.

3.3.1.1.2. *Pokazatelj – Trajanje putovanja*

Pokazatelj trajanja putovanja odnosi se na trajanje svakog pojedinog putovanja u promatranom vremenskom okviru. Srednje trajanje putovanja predstavlja srednju vrijednost vremenskog trajanja svih putovanja u određenom vremenskom intervalu između dva urbana područja [89].

Pokazatelj trajanja putovanja u pravilu ovisi o veličini grada, broju stanovnika, strukturi grada i odabranom prijevoznom sredstvu. U urbanim uvjetima, putovanjem od jednog sata može se prevaliti sljedeće prosječne udaljenost u ovisnosti o prijevoznom sredstvu: pješaćenjem pet kilometara, javnim gradskim prijevozom (tramvaj, autobus) 15 km, biciklom 15 km, automobilom do 30 km. U prosjeku, neovisno o veličini grada i navedenim pokazateljima, prosječno trajanje putovanje na posao u zemljama razvijenog svijeta iznosi 30 minuta u jednom smjeru, neovisno o promatranom modu prijevoza [26]. Uzevši u obzir navedene činjenice, za potrebe definiranja pokazatelja u svrhu anketiranja, vrijednosti prosječnih trajanja putovanja bit

će podijeljene u tri kategorije, i to u: kratko trajanje putovanja, srednje trajanje putovanja i dugo trajanje putovanja.

Vrijeme putovanja i mobilnost u izravnoj su vezi, tako da, prema literaturi, mobilnost ovisi o vremenu putovanja, na način da je mobilnost veća kada je prosječno vrijeme putovanja manje [28], odnosno mobilnost se povećava smanjenjem vremena putovanja [29].

Ispitanicima je u anketnom upitniku pokazatelj trajanja putovanja definiran na sljedeći način:

pokazatelj trajanja putovanja odnosi se na trajanje svakog pojedinog putovanja. Obzirom da je u pretpostavkama navedeno da je najduže trajanje putovanja 60 minuta, a da je prosječno trajanje putovanja 30 minuta, vrijednosti pokazatelja trajanja putovanja u apsolutnim su iznosima podijeljeni u tri kategorije. Pokazatelj trajanja putovanja u apsolutnom smislu može imati tri vrijednosti, kako je prikazano u tablici 24 **Error! Not a valid bookmark self-reference..**

Tablica 24. Pokazatelj trajanja putovanja

Pokazatelj trajanja putovanja	Trajanje putovanja	Zamjenska varijabla
Kratko trajanje putovanja	< 20 min	1
Srednje trajanje putovanja	21 < x <40 min	2
Dugo trajanje putovanja	>41 min	3

Međutim, kako bi se taj pokazatelj mogao koristiti u svim urbanim okružjima, odnosno u gradovima svih veličina, potrebno ga je relativizirati. Vrijednost pokazatelja trajanja putovanja može se relativizirati tako da se izračuna udio pojedinog putovanja u odnosu na najduže registrirano putovanje, pri čemu se vrijednost trajanja putovanja pojedinog putovanja normalizira u odnosu na putovanje koje je najduže trajalo u karakterističnom danu. Pri tome se putovanjem koje je najduže trajalo smatra ono putovanje koje je u vremenskom smislu trajalo najduže, a da su pritom i izvor i odredište ostali unutar iste urbane aglomeracije, odnosno područja pokrivanja. Iz tog razloga, vrijednost pokazatelja putovanja se može definirati kao u tablici 25.

Tablica 25. Pokazatelj trajanja putovanja (relativna vrijednost)

Pokazatelj trajanja putovanja	Trajanje putovanja	Zamjenska varijabla
Kratko trajanje putovanja	do 33% najdužeg putovanja	1
Srednje trajanje putovanja	od 34 – 66% najdužeg putovanja	2
Dugo trajanje putovanja	od 67% do 100% najdužeg putovanja	3

Ukoliko je vrijednost pokazatelja trajanja putovanja jednaka nuli, odnosno putovanje je trajalo 0 sati, onda se putovanje nije niti dogodilo te je mobilnost jednaka nuli, odnosno mobilnosti nema.

3.3.1.1.3. Pokazatelj - Prijedeni put (udaljenost)

Pokazatelj udaljenosti koristi se kao aproksimacija prijednog puta. Odnosi se na udaljenost koju je korisnik prevalio na putovanju između pojedinih urbanih područja, odnosno udaljenost između izvora i odredišta putovanja.

Pokazatelj duljine putovanja ili prijednog puta u pravilu se razlikuje između različitih urbanih aglomeracija jer može ovisiti o broju stanovnika, gustoći stanovanja, površini grada i postojanju atraktora. Kroz povijest se širenjem urbane površine povećava i duljina putovanja. Također, u urbanim aglomeracijama približno istih veličina mogu se pojaviti znatna odstupanja u prosječnim duljinama putovanja, što ovisi o prostornoj strukturi grada i njegovoj namjeni površina [25]. Odnos prosječne duljine putovanja i broja stanovnika jest nelinearan, tako da za gradove od 100.000 stanovnika prosječna duljina putovanja iznosi 6 km, za gradove od milijun stanovnika iznosi 9,5 km, a za gradove od pet milijuna stanovnika iznosi 10 km [26]. Pokazatelj udaljenosti ili prijednog puta u izravnoj je vezi s mobilnošću, tako da, prema literaturi, mobilnost ovisi o prijednom putu na način da, što je prijedni put veći, veća je i mobilnost [68]. Stoga su za potrebe definiranja pokazatelja u svrhu anketiranja, vrijednosti prosječnih duljina putovanja podijeljene u tri kategorije, i to na: putovanja malih udaljenosti, putovanja srednjih udaljenosti i putovanja velikih udaljenosti.

Ispitanicima je u anketnom upitniku pokazatelj prijednog puta definiran na sljedeći način:

Pokazatelj udaljenosti odnosi se na udaljenost koju je korisnik prevalio na putovanju između pojedinih urbanih područja, odnosno predstavlja udaljenost između izvora i odredišta putovanja.

U apsolutnom smislu, pokazatelj udaljenosti može imati tri vrijednosti, kako je prikazano u tablici 26.

Tablica 26. Pokazatelj prijeđenog puta (udaljenosti)

Kategorije	Udaljenost	Zamjenska varijabla
Mala udaljenost	< 5 km	1
Srednja udaljenost	$5 < x < 15$ km	2
Velika udaljenosti	>15 km	3

Međutim, kako bi se taj pokazatelj mogao koristiti u svim urbanim okruženjima, odnosno u gradovima svih veličina, potrebno ga je relativizirati. Vrijednost pokazatelja dužine putovanja može se relativizirati tako da se izračuna udio pojedinog putovanja u odnosu na najduže registrirano putovanje, pri čemu se vrijednost prijeđenog puta pojedinog putovanja normalizira u odnosu na najduže putovanje u karakterističnom danu. Pritom se najdužim putovanjem smatra ono putovanje tijekom kojeg je prijeđena udaljenost najveća, a da su pritom i izvor i odredište ostali unutar iste urbane aglomeracije, odnosno područja pokrivanja.

Iz tog razloga, vrijednost pokazatelja prijeđenog puta definira se kao u tablici 27.

Tablica 27. Pokazatelj prijeđenog puta (udaljenosti)

Pokazatelj prijeđenog puta	Trajanje putovanja	Zamjenska varijabla
Mala udaljenost	do 33% najdužeg putovanja	1
Srednja udaljenost	od 34 – 66% najdužeg putovanja	2
Velika udaljenosti	od 67% do 100% najdužeg putovanja	3

Ukoliko je vrijednost pokazatelja prijeđenog putovanja jednaka nuli, odnosno tijekom putovanja nije prijeđen put, putovanje se nije dogodilo tako da je mobilnosti jednaka nuli, odnosno mobilnosti nema.

3.3.1.2. Procjena mobilnosti

Ispitanici odgovarajućem scenariju pridjeljuju jednu od šest unaprijed definiranih ocjena mobilnosti, koje su detaljno obrazložene u poglavlju 0. Kategorije ocjenjivanja, kao i pripadajući opisi dani su u tablici 28. te u nastavku teksta. Prilikom definiranja opisa pojedinih razina mobilnosti, nisu korištene vrijednosti pokazatelja ili pokazatelji temeljem kojih ispitanici trebaju procijeniti mobilnost, kako takav opis niti u kojoj mjeri ne bi utjecao na odgovore ispitanika, te kako se ne bi utjecalo na objektivnost odgovora.

Tablica 28. Razina mobilnosti

Razina mobilnosti	Zamjenska varijabla
Izrazito visoka	6
Visoka	5
Viša-srednja	4
Niža- srednja	3
Niska	2
Izrazito niska	1

Kod „Izrazito visoke mobilnosti“ u prometnom sustavu vladaju uvjeti potpuno slobodnog prometnog toka, s punom slobodom manevriranja, gdje sudionici biraju brzinu kretanja i gdje sloboda kretanja nije narušena, a vremena čekanja su minimalna. Korisnici su izrazito zadovoljni.

Kod „Visoke mobilnosti“ u prometnom sustavu vladaju uvjeti slobodnog prometnog toka, sloboda manevriranja nije narušena, minimalno je ograničena brzina kretanja, sloboda kretanja je u maloj mjeri narušena, a vremena čekanja su rijetka i kratka. Korisnici su zadovoljni.

Kod „Više srednje mobilnosti“ u prometnom sustavu vladaju uvjeti stabilnog prometnog toka, sloboda manevriranje je ograničena, ograničena je brzina kretanja, ograničena je sloboda kretanja i vremena čekanja su osjetna. Korisnici su uglavnom zadovoljni.

Kod „Niže srednje mobilnosti“ u prometnom sustavu vladaju uvjeti nestabilnog prometnog toka, s malom mogućnosti manevriranja, s bitno ograničenim brzinama, jasno narušenom slobodom kretanja i većim prosječnim vremenima čekanja. Korisnici su uglavnom nezadovoljni.

Kod „Niske mobilnosti“ u prometnom sustavu vladaju uvjeti nestabilnog prometnog toka s kretanjem u nizu, sloboda manevriranja je gotovo stalno narušena, brzina kretanja je značajno ograničena i javljaju se zastoji, sloboda kretanja je gotovo stalno narušena, vremena čekanja su velika. Korisnici su nezadovoljni.

Kod „Izrazito niske mobilnosti“ u prometnom sustavu vladaju uvjeti usiljenog-prisilnog prometnog toka, sloboda manevriranja je onemogućena u potpunosti, brzina kretanja je manja od kritičnih brzina, sloboda kretanja je onemogućena u potpunosti, vremena čekanja su izrazito velika. Korisnici su izrazito nezadovoljni.

3.3.1.3. Anketna pitanja

Anketni upitnik sastoji se od skupa pitanja. Putem pitanja prikuplja se mišljenje eksperta („crpljenje znanja“) o tome kako i u kojoj mjeri kombinacija vrijednosti pojedinih pokazatelja utječe na procjenu mobilnosti. Anketna pitanja obuhvaćaju sve permutacije vrijednosti pokazatelja uključenih u procjenu mobilnosti. Ekspert na pitanja odgovara na način da na osnovi vlastitog znanja i iskustva u svakom pitanju pridijeli odgovarajuću vrijednost procjene mobilnosti. Pitanja se formiraju korištenjem vrijednosti pokazatelja prikazanih u tablici 29.

Tablica 29. Vrijednosti pokazatelja

Broj putovanja	Pokazatelj trajanja putovanja	Pokazatelj prijedene udaljenosti
Mali broj putovanja	Kratko trajanje putovanja	Mala udaljenost
Srednji broj putovanja	Srednje trajanje putovanja	Srednja udaljenost
Velik broj putovanja	Dugo trajanje putovanja	Velika udaljenosti

Pitanja se formiraju tako da obuhvaćaju vrijednosti svih uključenih pokazatelja. Primjer pitanja izgleda ovako:

Ako je <broj putovanja>, <pokazatelj trajanja putovanja> i <pokazatelj prijedene puta (udaljenosti)>, mobilnost je <procjena mobilnosti>.

Odnosno, stave li se stvarne vrijednosti pokazatelja, primjer scenarija, odnosno anketnog upitnika izgleda ovako:

Ako je u prometnom sustavu prisutan mali broj putovanja, pojedinačno putovanje je trajalo kratko, a prijedena udaljenost je mala, mobilnost je ____? ____.

Svaki od pokazatelja ima tri moguće vrijednosti, dok procjena mobilnosti ima šest vrijednosti. Permutacijom svih vrijednosti pokazatelja dolazimo do ukupnog broja od 27 pitanja, koja predstavljaju anketna pitanja, odnosno predložene scenarije mobilnosti. Svi scenariji prikazani su u tablici 30.

Primjer 1.: Ukoliko je (*primjerice, tijekom noći*) ukupni broj putovanja u urbanom okruženju mali, a moje je putovanje trajalo kratko, prilikom čega sam prešao srednju udaljenost, po mojoj procjeni mobilnost je _____.

Primjer 2.: Ukoliko je (*primjerice, tijekom jutarnjeg vršnog opterećenja*) ukupni broj putovanja u urbanom okruženju mali, a moje je putovanje trajalo dugo, prilikom čega sam prešao malu udaljenost, po mojoj procjeni mobilnost je _____.

Tablica 30. Popis scenarija za procjenu mobilnosti

Rb.	Broj putovanja	Trajanje putovanja	Udaljenost	Procjena mobilnosti
1	Mali broj putovanja	Kratko trajanje putovanja	Mala udaljenost	?
2	Mali broj putovanja	Kratko trajanje putovanja	Srednja udaljenost	?
3	Mali broj putovanja	Kratko trajanje putovanja	Velika udaljenosti	?
4	Mali broj putovanja	Srednje trajanje putovanja	Mala udaljenost	?
5	Mali broj putovanja	Srednje trajanje putovanja	Srednja udaljenost	?
6	Mali broj putovanja	Srednje trajanje putovanja	Velika udaljenosti	?
7	Mali broj putovanja	Dugo trajanje putovanja	Mala udaljenost	?
8	Mali broj putovanja	Dugo trajanje putovanja	Srednja udaljenost	?
9	Mali broj putovanja	Dugo trajanje putovanja	Velika udaljenosti	?
10	Srednji broj putovanja	Kratko trajanje putovanja	Mala udaljenost	?
11	Srednji broj putovanja	Kratko trajanje putovanja	Srednja udaljenost	?
12	Srednji broj putovanja	Kratko trajanje putovanja	Velika udaljenosti	?
13	Srednji broj putovanja	Srednje trajanje putovanja	Mala udaljenost	?
14	Srednji broj putovanja	Srednje trajanje putovanja	Srednja udaljenost	?
15	Srednji broj putovanja	Srednje trajanje putovanja	Velika udaljenosti	?
16	Srednji broj putovanja	Dugo trajanje putovanja	Mala udaljenost	?
17	Srednji broj putovanja	Dugo trajanje putovanja	Srednja udaljenost	?
18	Srednji broj putovanja	Dugo trajanje putovanja	Velika udaljenosti	?
19	Velik broj putovanja	Kratko trajanje putovanja	Mala udaljenost	?
20	Velik broj putovanja	Kratko trajanje putovanja	Srednja udaljenost	?
21	Velik broj putovanja	Kratko trajanje putovanja	Velika udaljenosti	?
22	Velik broj putovanja	Srednje trajanje putovanja	Mala udaljenost	?
23	Velik broj putovanja	Srednje trajanje putovanja	Srednja udaljenost	?
24	Velik broj putovanja	Srednje trajanje putovanja	Velika udaljenosti	?
25	Velik broj putovanja	Dugo trajanje putovanja	Mala udaljenost	?
26	Velik broj putovanja	Dugo trajanje putovanja	Srednja udaljenost	?
27	Velik broj putovanja	Dugo trajanje putovanja	Velika udaljenosti	?

Primjer formiranja pitanja prikazan je na slici 21., a primjer odgovorenog scenarija na slici 22.



Slika 21. Proces formiranja scenarija za procjenu urbane mobilnosti



Slika 22. Primjer odgovora jednog od eksperata

Putem upitnika, eksperti potom pridjeljuju pitanju vrijednost iz ponuđene skale po kojoj je procjena mobilnosti rangirana u šest kategorija i to kao „Izrazito visoka (6), Visoka (5), Viša-srednja (4), Niža-srednja (3), Niska (2) i Izrazito niska (1)“.

Po završetku procesa anketiranja, odgovori svih eksperata koji sudjeluju u istraživanju bit će na odgovarajući način obrađeni, te će se potom koristiti u daljnjim koracima u postupku procjene mobilnosti.

3.3.1.3.1. Dodatni scenariji

Također, scenarijima dobivenim anketiranjem pridodat će se i tri dodatna logična scenarija koji ukazuju na to da, ukoliko je vrijednost bilo kojeg od pokazatelja jednaka nuli, tada je i mobilnost jednaka nuli, odnosno mobilnosti nema.

Dodatni scenariji stoga kažu sljedeće:

- a) Ukoliko je vrijednost pokazatelja broja putovanja jednaka nuli, odnosno između izvora i odredišta nije zabilježeno niti jedno putovanja, mobilnost je jednaka nuli.
- b) Ukoliko je vrijednost pokazatelja trajanja putovanja jednaka nuli, odnosno putovanje je trajalo 0 sati, onda se putovanje nije niti dogodilo te je mobilnost jednaka nuli, odnosno mobilnosti nema.
- c) Ukoliko je vrijednost pokazatelja dužine putovanja jednaka nuli, odnosno tijekom putovanja nije prijeđen put, putovanje se nije dogodilo, tako da je mobilnost jednaka nuli, odnosno mobilnosti nema.

3.3.2. Rezultati ankete

Anketiranje stručnjaka provedeno je na planiranim radionicama i putem telekonferencija. Izabrani su stručnjaci iz Republike Hrvatske i inozemstva koji se bave

urbanom mobilnošću i to: stručnjaci za mobilnost iz akademske zajednice, stručnjaci koji se bave mobilnošću iz privatnog sektora te stručnjaci iz javnog sektora koji se bave mobilnošću na razini pojedinih gradova.

Za sudionike iz Zagreba radionice su organizirane na fizičkim lokacijama, a za stručnjake iz ostatka Hrvatske te iz inozemstva, radionice su organizirane putem videokonferencijske platforme. Svaka radionica je bila koncipirana na način da je u prvom, uvodnom dijelu uslijedila kratka prezentacija cilja istraživanja te je objašnjena pozadina istraživanja. Nakon toga je uslijedila diskusija i razgovor o potencijalnim nejasnoćama, da bi nakon toga slijedilo ispunjavanje anketnog upitnika. Anketa je obuhvatila **36 stručnjaka**, i to 16 stručnjaka iz domene znanstvene zajednice, 11 stručnjaka iz privatnog sektora koji se bave mobilnošću te 9 stručnjaka iz javnog sektora koji su zaduženi za mobilnost. Iz Republike Hrvatske bio je 20 ispitanika, a ostali su bili iz inozemstva. Detalji s radionica su prikazani na slici 23.



Slika 23. Detalji s radionica s ekspertima


Preliminarna analiza rezultata ankete data je u nastavku i prikazana je u tablici 31. Za svaki scenarij prikazana je minimalna i maksimalna ocjena mobilnosti koju su eksperti pridijelili, prikazana je prosječna ocjena, izračunata je standardna devijacija. Prikazana je i razdioba ocjena (u postotku) za svaki scenarij procjene mobilnosti. Podaci prikupljeni anketom („iscrpljeno znanje“) potom će biti korišteni kao ulazni podaci za učenje ekspertnog sustava.

Tablica 31. Analiza rezultata anketnog upitnika

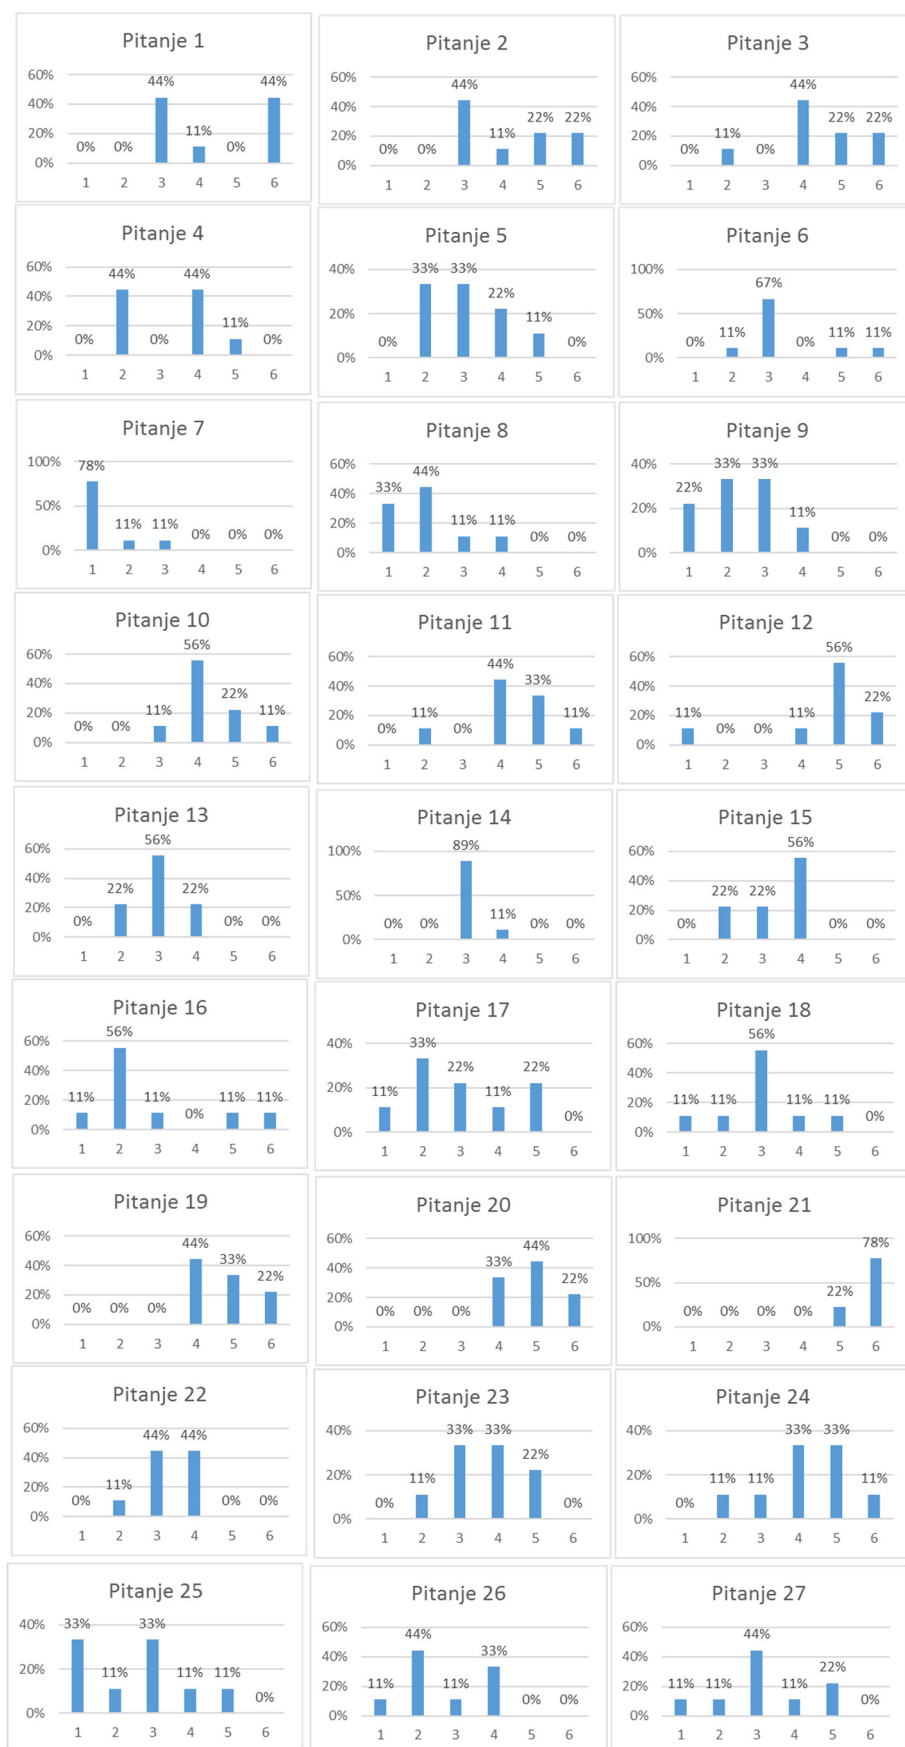
						Ocjena mobilnosti					
	No.	MIN	MAX	AVG	STDEV	1	2	3	4	5	6
Scenarij	1	3	6	4,44	1,44	0%	0%	44%	11%	0%	44%
	2	3	6	4,22	1,24	0%	0%	44%	11%	22%	22%
	3	2	6	4,44	1,18	0%	11%	0%	44%	22%	22%
	4	2	5	3,22	1,15	0%	44%	0%	44%	11%	0%
	5	2	5	3,11	1,01	0%	33%	33%	22%	11%	0%
	6	2	6	3,44	1,18	0%	11%	67%	0%	11%	11%
	7	1	3	1,33	0,68	78%	11%	11%	0%	0%	0%
	8	1	4	2,00	0,96	33%	44%	11%	11%	0%	0%
	9	1	4	2,33	0,96	22%	33%	33%	11%	0%	0%
	10	3	6	4,33	0,83	0%	0%	11%	56%	22%	11%
	11	2	6	4,33	1,07	0%	11%	0%	44%	33%	11%
	12	1	6	4,67	1,43	11%	0%	0%	11%	56%	22%
	13	2	4	3,00	0,68	0%	22%	56%	22%	0%	0%
	14	3	4	3,11	0,32	0%	0%	89%	11%	0%	0%
	15	2	4	3,33	0,83	0%	22%	22%	56%	0%	0%
	16	1	6	2,78	1,57	11%	56%	11%	0%	11%	11%
	17	1	5	3,00	1,35	11%	33%	22%	11%	22%	0%
	18	1	5	3,00	1,07	11%	11%	56%	11%	11%	0%
	19	4	6	4,78	0,80	0%	0%	0%	44%	33%	22%
	20	4	6	4,89	0,75	0%	0%	0%	33%	44%	22%
	21	5	6	5,78	0,42	0%	0%	0%	0%	22%	78%
	22	2	4	3,33	0,68	0%	11%	44%	44%	0%	0%
	23	2	5	3,67	0,96	0%	11%	33%	33%	22%	0%
	24	2	6	4,22	1,15	0%	11%	11%	33%	33%	11%
	25	1	5	2,56	1,36	33%	11%	33%	11%	11%	0%
	26	1	4	2,67	1,07	11%	44%	11%	33%	0%	0%
	27	1	5	3,22	1,24	11%	11%	44%	11%	22%	0%

Preliminarna analiza podataka napravljena je u svrhu provjere konzistentnosti odgovora, te identifikacije pojedinih pitanja gdje postoji izrazito slaganje ili razlika u mišljenju eksperata. Razlike u mišljenju eksperata su očekivane, jer eksperti mobilnost sagledavaju iz različitih područja, u ovisnosti o svom području proučavanja. Najveći konsenzus eksperata zabilježen je u pitanjima 14 (Srednji broj putovanja - Srednje trajanje putovanja - Srednja udaljenost) i 21 (Velik broj putovanja - Kratko trajanje putovanja - Velika udaljenosti). U pitanju broj 14 raspon ocjena mobilnosti je u intervalu od 3 do 4, uz prosječnu ocjenu od 3,11, kao i u pitanju broj 21

gdje je raspon odgovora u intervalu od 5 do 6, uz prosječnu vrijednost od 5,78. Na nekoliko pitanja, i to pitanja 12 (Srednji broj putovanja - Kratko trajanje putovanja -Velika udaljenosti) i 16 (Srednji broj putovanja - Dugo trajanje putovanja- Mala udaljenost) eksperti su istom pitanju dodjeljivali i najveću i najmanju ocjenu, pri čemu prosječna ocjena mobilnosti u pitanju 12 iznosi 4,67, a prosječna ocjena mobilnosti u pitanju 16 iznosi 2,78. Najveći broj eksperata (78%) je ocjenom jedan ocijenio mobilnost opisanu pitanjem broj 7 (Mali broj putovanja - Dugo trajanje putovanja - Mala udaljenost), dok je ocjenom dva najveći broj eksperata (56%) ocijenio mobilnost opisanu pitanjem broj 16 (Srednji broj putovanja - Dugo trajanje putovanja - Mala udaljenost). Najveći broj eksperata (89%) je ocjenom tri ocijenio mobilnost opisanu pitanjem broj 14 (Srednji broj putovanja - Srednje trajanje putovanja - Srednja udaljenost). Ocjenom četiri najveći broj eksperata (56%) ocijenio je mobilnost opisanu pitanjima broj 10 (Srednji broj putovanja - Kratko trajanje putovanja - Mala udaljenost) i 15 (Srednji broj putovanja - Srednje trajanje putovanja - Velika udaljenosti). Ocjenom pet najveći broj eksperata (56%) je ocijenio mobilnost opisanu pitanjem broj 12 (Srednji broj putovanja - Kratko trajanje putovanja - Velika udaljenosti). Najveći broj eksperata (78%) je ocijenio ocjenom šest mobilnost opisanu pitanjem broj 21 (Velik broj putovanja - Kratko trajanje putovanja - Velika udaljenosti). Odnos minimalne, prosječne i maksimalne ocjene mobilnosti za svako anketno pitanje prikazan je na slici 24, a histogramski prikaz zatupljenosti pojedinih odgovora na svako pitanje prikazan je na slici 25.



Slika 24. Odnos minimalne, prosječne i maksimalne ocjene mobilnosti za svako anketno pitanje



Slika 25. Histogramski prikaz rezultata ankete

3.4. Metoda neizrazite logike

Za definiranje modela procjene mobilnosti koristit će se metoda neizrazite logike, odnosno ANFIS (engl. *adaptive neuro-fuzzy inference system*) tehnika strojnog učenja koja koristi neizrazitu logiku kako bi pretvorila dane ulazne podatke u odgovarajuće izlazne vrijednosti. Teorijski pregled metode neizrazite logike i ANFIS-a je dan u sljedeća dva potpoglavlja.

3.4.1. Neizrazita logika

Koncept neizrazite logike (engl. *fuzzy logic*) definiran je u sklopu teorije neizrazitih skupova, koji omogućavaju modeliranje semantičkih neodređenosti govornog jezika [90], [91]. Neizrazita logika predstavlja logički sustav u kojem istinitost neke tvrdnje može poprimiti bilo koju vrijednost između 1 (istinito) i 0 (neistinito). Takav je pristup širi od binarne Booleove logike, pa omogućuje matematičko modeliranje nepreciznih podataka (npr. iskaz: u sobi je prilično toplo). Teorijske osnove neizrazite logike postavio je 1965., na Sveučilištu Berkley u Kaliforniji, azerbajdžanski znanstvenik rusko-iranskoga podrijetla Lotfi Zadeh (1921.) [92].

U tradicionalnoj teoriji skupova, pripadnost objekta skupu je egzaktno određena, tako da je objekt ili unutar skupa, ili je izvan njega. Kada se pripadnost objekta skupu izražava funkcijski, tada funkcija pripadnosti objekta x skupu A , $\mu_A(x)$ ima dvije vrijednosti () i definirana je kao (20):

$$\mu_A(x) = \begin{cases} 1, & \text{za } x \in A \\ 0, & \text{za } x \notin A \end{cases} \quad (20)$$

Za neke primjene podjela objekata na skupove, stroga definicija pripadnosti nije prikladna, jer nije moguće odrediti odgovarajuću granicu između skupova [93], [94], [95]. Karakterističan primjer jest ljudska percepcija cijene za određeni proizvod ili uslugu, gdje se iznosi vrlo bliske vrijednost mogu naći u različitim skupovima. Primjerice, u gradu od milijun stanovnika prosječno trajanje putovanja na posao može biti u rasponu od 10 do 60 minuta. Prosječan građanin bi putovanje koje traje između 50 i 60 minuta mogao nazvati vrlo dugačkim, pri čemu, primjerice, putovanje koje traje 49 minuta ne ulazi u taj skup, premda je vrlo blizu njemu i razlika u cijeni je zanemariva. Granica skupa „dugo trajanje“ bi se mogla pomaknuti i na 49 minuta, ali tada bi se isti problem javio sa putovanjem koje traje 48 minuta, itd. Takva pripadnost skupu može se putem funkcije pripadnosti izraziti na sljedeći način (21):

$$\mu_{dugo\ trajanje}(x) = \begin{cases} 1, & \text{za } x \geq 50 \text{ min} \\ 0, & \text{za } x < 50 \text{ min} \end{cases} \quad (21)$$

Teorija neizrazitih skupova dozvoljava djelomičnu pripadnost elemenata skupu, gdje se funkcijske vrijednosti funkcije pripadnosti nalaze unutar intervala $[0,1]$. Kod neizrazitih skupova, vrijednost 0 označava da je element izvan skupa, 1 da je unutar skupa, a vrijednosti između označavaju djelomičnu pripadnost, koja kod tradicionalnih skupova ne postoji (primjer (22)) [90], [91], [93]–[95].

$$\mu_{dugo\ trajanje}(x) = \begin{cases} 1, & \text{za } x \geq 50 \text{ min} \\ (0 - 1), & \text{za } 40 \leq x < 50 \text{ min} \\ 0, & \text{za } x < 40 \text{ min} \end{cases} \quad (22)$$

Pojmovi karakteristični za govornu komunikaciju, kao što su dugo – kratko, skupo – jeftino, staro – mlado, vruće – hladno, visoko – nisko u okvirima teorije neizrazitih skupova predstavljaju neizrazite skupove koji određuju jezične varijable, pri čemu jedna jezična varijabla (npr., cijena) može imati više vrijednosti (niska, srednja, visoka), odnosno jednako toliko neizrazitih skupova. Neizraziti skup određen je funkcijom pripadnosti, a način definiranja funkcije pripadnosti ovisi o tipu podataka koji se grupiraju, kao i tipu domene nad kojim se zadaju [90], [91], [93]–[95]. Neizrazita logika se najčešće koristi za modeliranje složenih neizrazitih sustava u kojima se primjenom drugih metoda teško može utvrditi međuovisnost koja postoji između pojedinih varijabli. Koncept neizrazite logike ugrađen je u neizrazite sustave.

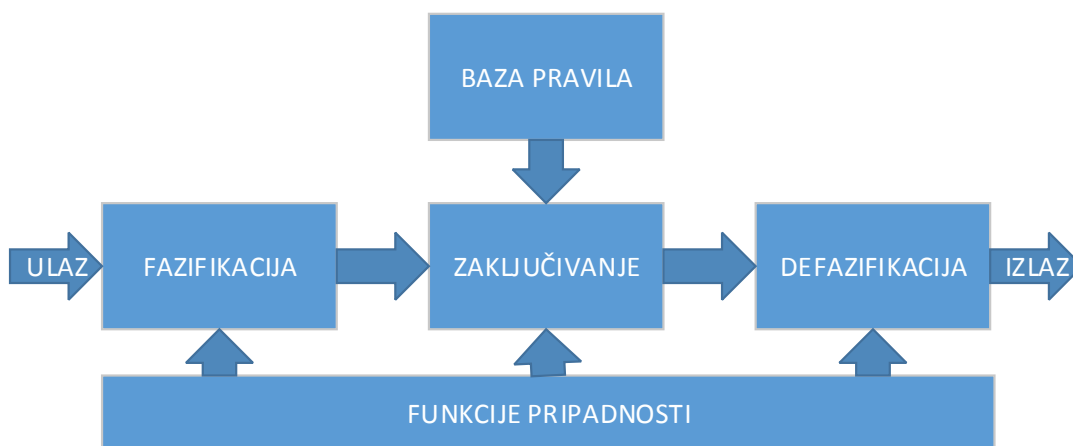
3.4.1.1. *Neizraziti sustavi*

Neizraziti sustav (slika 26.) se može definirati kao bilo koji statički ili dinamički sustav koji koristi neizrazitu logiku i pripadajući matematički okoliš [90], [91]. Neizraziti sustav se sastoji od tri temeljna procesa i to:

- a) Fazifikacija (engl. *fuzzification*) kao proces digitalno-neizravne pretvorbe. Unutar procesa izračunava se stupanj pripadnosti μ lingvističkih varijabli pomoću određene

funkcije pripadnosti. Sve lingvističke varijable s mogućim vrijednostima (skupovima) nalaze se unutar definiranih pravila.

- b) Zaključivanje (engl. *inference*). Tijekom procesa zaključivanja numeričke vrijednosti varijabli (engl. *crisp values*) pretvaraju se u lingvističke (neizrazite) varijable te se za danu situaciju pronalazi prikladno pravilo (AKO-TADA), koje generira lingvističku vrijednost varijable.
- c) Defazifikacija (engl. *defuzzification*) kao proces neizravno-digitalne pretvorbe. Proces defazifikacije je proces u kojem se neizravne vrijednosti varijabli dobivene kao rezultat procesa zaključivanja pomoću određenih postupaka i funkcija pripadnosti pretvaraju u numeričke vrijednosti.



Slika 26. Shematski prikaz elemenata neizrazitog sustava

Dakle, neizraziti sustavi koriste se za obradu neizrazitih ulaznih, odnosno za transformaciju ulaznih podataka koji koriste oblik digitalno neizrazite pretvorbe. Izlaz iz modela može biti izrazita veličina ili neizraziti skup, koji je rezultat posljednjeg koraka u procesu, koraka neizrazito-digitalne pretvorbe [90], [91], [93]–[95].

3.4.1.2. Proces fazifikacije

Polazna točka za neizrazite skupove je poopćavanje neizrazitog skupa iz para brojeva [0,1]. Proširenjem neizrazitog skupa mijenjamo prirodu karakteristične funkcije, koja nosi

naziv funkcija pripadnosti (engl. *membership function*). Sukladno činjenici da interval $[0,1]$ sadrži beskonačno mnogo brojeva, u teoriji je moguće definirati i beskonačno mnogo stupnjeva pripadnosti [47]. Neizrazitom skupu pojedine neizrazite varijable dodjeljuje se određeni oblik funkcije pripadnosti unutar skupa. Oblici funkcija pripadnosti mogu biti različiti, a najčešće su trapezoidni, trokutasti, funkcija S-tipa itd. Funkcije pripadnosti su pandan aktivacijskim funkcijama kod neuronskih mreža. Funkcija pripadnosti određuje stupanj pripadanja nekog objekta pripadnosti skupu [50]–[52] te predstavljaju alat za označavanje fleksibilnosti pripadanju skupu, te za modeliranje i kvantificiranje simboličkih značenja. Definiraju se putem individualnog zapisa neizrazitih raspona, pomoću statističkih podataka ili korištenjem neuronskih mreža [50]–[52].

Ako je X osnovni skup, a x je određeni element skupa X , tada se neizraziti skup A koji je definiran na X -u može napisati kao uređeni par (23):

$$A = \{(x, \mu_A(x))\}, x \in X \quad (23)$$

pri čemu svaki par $(x, \mu_A(x))$ predstavlja neizraziti broj kojem je x prvi član, a drugi član je njegova pripadnost osnovnom skupu A ($\mu_A(x)$) [90], [91], [93]–[95].

Kontinuirani skup može se definirati kao


$$A = \int_x^{dx} \frac{\mu_A(x)}{x} \quad (24)$$

Dakle, ukoliko neki element $x \in X$ sigurno pripada skupu A , tada je stupanj pripadnosti skupu $\mu(X) = 1$, a ukoliko element ne pripada skupu A , onda je stupanj pripadnosti skupu $\mu(X) = 0$. Ukoliko je vrijednost stupnja pripadnosti skupu $\mu(X)$ bilo koji broj iz intervala $[0,1]$, a koji je različit od 0 i 1, tada se taj broj interpretira kao stupanj pripadnosti elementa skupu A . Veličina tog broja definira i veću ili manju mogućnost pripadnosti skupu, odnosno što je taj broj veći (bliže broju jedan), mogućnost pripadnosti skupu A je veća, a što je manji (bliži broju nula), mogućnost pripadnosti skupu A je manja. Funkcija $\mu(X)$ tako se definira kao funkcija


pripadnosti (engl. *membership function*), a skup A se definira kao neizrazit skup i zapisuje se kao $(A, \mu(X))$.

Funkcije pripadnosti sastoje se od karakterističnih elemenata. Elementi funkcije pripadnosti (slika 27), unutar intervala $[0,1]$ su:

- Jezgra (engl. *core*) – Definira se kao klasičan skup svih elemenata za koje je vrijednost funkcije jednaka 1.
- Osnovica (engl. *support*) – Definira se kao klasičan skup svih elemenata za koje je vrijednost funkcije veća od 0.
- Granice (engl. *boundary*) – Definira kao klasičan skup svih elemenata za koje je vrijednost funkcije pripadnosti manja od 1, a ovise od same funkcije pripadnosti.
- Visina (engl. *height*) – Definira se kao klasičan skup svih elemenata za koje je vrijednost funkcije maksimalna.
- Polovište (engl. *crossover point*) – Definira se kao klasičan skup svih elemenata za vrijednost funkcije od 0.5.




Slika 27. Karakteristični elementi funkcije pripadnosti




Slika 28. Shematski prikaz najčešćih funkcija pripadnosti

Teorija neizrazitih skupova poznaje više funkcija pripadnosti, međutim, u praksi se najčešće koriste funkcije pripadnosti Z-tipa, funkcija tipa trapez, funkcija tipa trokut i funkcija S-tipa (slika 28) [48], [50].

Kao primjer, promotrimo jednu funkciju pripadnosti tipa trokut (slika 30.). Funkcija je definirana parametrima $[a,b,c]$. Parametar „a“ predstavlja lijevi presjek funkcije sa stupnjem pripadnosti $\mu = 0$. Parametar „b“ predstavlja središnji vrh funkcije sa stupnjem pripadnosti $\mu = 1$. Parametar „c“ predstavlja desni presjek funkcije s pripadnošću $\mu = 0$. Kod neizrazitih skupova karakteristično je da se funkcije pripadnosti mogu međusobno preklapati (slika 30.) [90], [91], [93]–[97].



Slika 29. Funkcija pripadnosti tipa trokut



Slika 30. Preklapanje skupova unutar univerzalnog skupa

3.4.1.3. Zaključivanje (engl. *Inference*)

Koncept neizrazite logike zamišljen je na način da primjeni pravila karakteristična za ljudsko razmišljanje u modeliranju. U prethodnom koraku numeričke vrijednosti su zamijenjene tzv. lingvističkim varijablama koje su bliže ljudskom načinu razmišljanja, a na njima se zasniva proces zaključivanja. Osim toga, ljudsko razmišljanje, koje se izražava riječima i rečenicama, temelji se na neizrazitim propozicijama. Neizraziti sustav za zaključivanje (engl. *fuzzy inference system*, FIS) je sustav za zaključivanje koji se temelji na konceptima znanja, kao što su teorija neizrazitih skupova, skup AKO-TADA pravila i teorija neizrazitog zaključivanja. Sastoji se od baze pravila, rječnika i mehanizma za zaključivanje. Baza pravila sadrži sva AKO-TADA pravila, rječnik sadrži definicije funkcija pripadnosti koje se koriste uz neizrazita pravila, a sustav za zaključivanje sastoji se od modela za zaključivanje, koji mogu biti tipa Mamdani ili Sugeno [90], [91], [93]–[95].

Polazna varijabla za kvantificiranje modela ljudskog razmišljanja jest neizravna propozicija. Ona se može poopćeno definirati kao $x = A$, pri čemu je A neizrazita (jezična, lingvistička) vrijednost definirana neizrazitim skupom nad domenom varijable. Neizrazita propozicija uspoređuje varijablu x i skup A , odnosno određuje stupanj pripadnosti varijable x neizrazitom skupu A . Za njihovo povezivanje koriste se veznici I (engl. *AND*), ILI (engl. *OR*) te AKO-TADA (engl. *IF-THEN*). Neizrazito pravilo definira se kao kombinacija neizravnih brojeva i veznika [90], [91], [93]–[97].

Sintaksa pravila prikazana je u nastavku (25):

$$\text{AKO } x \text{ je } A \text{ i } y \text{ je } B \text{ TADA } z \text{ je } C \quad (25)$$

U prikazanom pravilu uvjet je definiran s $x \text{ je } A \text{ i } y \text{ je } B$, a zaključak pravila je definiran s $z \text{ je } C$. Neizraziti sustavi definiraju se korištenjem većeg broja pravila, koji se organiziraju u skup pravila, odnosno tvore bazu neizrazitih pravila. Za matematičku interpretaciju neizrazitih pravila koriste se neizrazite relacije koje definiraju kvantitativnu vezu između varijabli uvjeta i varijabli zaključka [50]–[54].

Primjer pravila koji se generiraju u sklopu neizrazitih sustava identični su onima kojima se koristimo u svakodnevnom govoru i zaključivanju. Primjer pravila je:

1. Ako je u restoranu usluga izvrsna i ako je hrana izvrsna, iznos napojnice je visok.
2. Ako je brzina velika i nailazi oštar zavoj, smanji brzinu.

Posljednji korak u ovom procesu jest samo zaključivanje. Razlikujemo dva tipa modela za zaključivanje i to model Mamdani i model Sugeno.

Model Mamdani predstavlja prvi model koji se koristio u teoriji neizrazite logike, a definirao ga je Ebrahim Mamdani 1975. godine. U prvoj primjeni, Mamdani je intervjuom iskusnih operatora parnog postrojenja opisao problem regulacije protoka i temperature pare, koje je potom kvantificirao. Mamdani model kao izlaznu vrijednost daje neizrazite skupove podataka.

Mamdani model se definira na sljedeći način. Neizraziti sustav s jednom ulaznom i jednom izlaznom varijablom, te tri pravila oblika, piše se kao (26):

$$\text{AKO } x \text{ je } A_i \text{ TADA } y \text{ je } B_i, i = 1, 2, 3 \quad (26)$$

pri čemu x i y predstavljaju ulazne i izlazne varijable iz skupova X i Y , nad kojima su zadane neizrazite vrijednosti A_i i B_i [90], [91], [93]–[97].

Za razliku od Mamdani modela, model Sugeno se razlikuje u načinu definiranja zaključka. Umjesto neizrazite, koristi izrazitu funkciju čiji su argumenti ulazne i izlazne varijable. Pravila Sugeno modela zadaju se u obliku (27):

$$AKO\ x\ je\ A_i\ i\ y\ je\ B_i, TADA\ y_i = f_i(x, y) \quad (27)$$

A_i i B_i su dijelovi neizrazitih skupova zadani nad domenama ulaznih varijabli x i y , a funkcija $f_i(x, y)$ predstavlja izrazitu funkciju zaključka. Funkcija f_i je polinom nultog ili prvog stupnja. Izlaz iz Sugeno modela uvijek je izrazit i određuje se interpolacijom zaključaka (28):

$$z = \frac{\sum_i \beta_i z_i}{\sum_i \beta_i} \quad (28)$$


pri čemu je β_i stupanj istinitosti premise pojedinog pravila, a $\beta_i z_i$ broj važećih pravila ili ukupan broj pravila neizrazitog sustava [90], [91], [93]–[95], [98].

3.4.1.4. Defazifikacija (engl. Defuzzification)

Defazifikacija je proces pretvaranja lingvističkih (simboličkih) rezultata dobivenih na temelju zaključivanja iz baze pravila u numeričke vrijednosti (engl. *crisp values*). Riječ je o procesu suprotnom od procesa fazifikacije, u kojem se brojevi pretvaraju u neizrazite skupove. Premda se za internu prezentaciju podataka u neizrazitom sustavu koriste neizraziti skupovi, izlaz mora biti određen i jasan broj. Postoji više metoda defazifikacije, najčešće se koriste sljedeće metode defazifikacije [90], [91], [93]–[95], [98]:

- Metoda težišta (engl. *center of gravity*) pri kojoj se kao izlazna vrijednost modela uzima vrijednost težišta geometrijskog tijela definiranog neizrazitim skupom.

- Metoda središta ukupne površine (engl. *center of area*) pri kojoj se kao izlazna vrijednost modela uzima vrijednosti središta ukupne površine za slučajeve gdje su površine neizrazitog skupa lijevo i desno od izlazne veličine identične.
- Metoda središnje točke maksimuma (engl. *mean of maximum*) pri kojoj se kao izlazna vrijednost modela uzima srednja vrijednost apscisa točaka u kojima funkcija pripadnosti izlaznog neizrazitog skupa dostiže svoj maksimum.



Slika 31. Defazifikacija korištenjem metode težišta

Promotrimo kao primjer metodu težišta. U njoj se izračunava središnja točka krivulje izlaznih funkcija pripadnosti. Ona predstavlja točku na geometrijskom obliku čije su koordinate jednake srednjoj vrijednosti svih točaka koje opisuju geometrijski lik. Ta točka predstavlja težište tog lika, te se u sklopu teorije neizrazite logike definira kao izlazna vrijednost. Njezina vrijednost na x osi dijeli površinu ispod funkcije pripadnosti na dva dijela. Izlazna vrijednost je vrijednost na kojoj presijeca liniju točke težišta na x-osi (slika 31). Metoda se može koristiti i na diskretnim funkcijama pripadnosti, kod kojih se izlazna vrijednost definira pomoću izraza (29):


$$x = \frac{\sum_i x_i \mu(x_i)}{\sum_i \mu(x_i)} \quad (29)$$

pri čemu je x izlazna vrijednost, x_i izlazna vrijednost funkcije pripadnosti i $\mu(x_i)$ stupanj vrijednosti pripadajuće funkcije pripadnosti [47], [48].

3.4.2. ANFIS neuronska mreža

ANFIS je višeslojni prilagodljivi sustav neizrazitog zaključivanja zasnovan na neuronskoj mreži, koji je definirao Jang 1993. godine [99], [100]. ANFIS predstavlja tehniku strojnog učenja koja koristi neizrazitu logiku kako bi pretvorila upisane ulazne podatke u odgovarajuće izlazne vrijednosti. Sadrži neuronsku mrežu kao strukturiranu mrežu koja se sastoji od određenog broja čvorova (neurona) međusobno povezanih pomoću usmjerenih veza. Svaki čvor karakterizira određena funkcija s fiksnim ili promjenljivim parametrima. Promjenu vrijednosti parametara uzrokuju adaptivni (što znači da njihovi izlazi ovise o parametrima koji se mijenjaju kroz mrežu, prolazeći kroz poveznice i druge čvorove) i neadaptivni (fiksni) čvorovi mreža, ali u sprezi s pravilima učenja koja specificiraju na koji će se način ti parametri mijenjati kako bi se minimalizirala propisana mjera greške. ANFIS kombinira prednosti dvije metode strojnog učenja (neizrazita logika i neuronska mreža). ANFIS radi na principu primjene metoda zaključivanja karakterističnih za neuronske mreže s ciljem određivanja parametra neizravnog sustava zaključivanja (*Fuzzy Inference System* – FIS) [99]. Rezultat je sustav koji omogućava korištenje dobro poznatih algoritama za učenje umjetnih neuronskih mreža, koji se ne mogu koristiti u sustavima za neizrazito zaključivanje, dok se istovremeno zadržava mogućnost korištenja neizrazite logike i neizrazitog zaključivanja.

ANFIS omogućava kreiranje i fino podešavanje neizrazitih uzročno-posljedičnih AKO-TADA (engl. *IF-THEN*) pravila kojima se opisuje ponašanje nekog kompleksnog sustava. ANFIS metoda omogućava rad s velikim skupovima podataka, ima podršku za različit broj funkcija pripadnosti, ima velike mogućnosti poopćavanja, omogućava stvaranje lingvističkih i numeričkih neizrazitih pravila za rješavanje problema [101], [102]. Prednost oblikovanja ANFIS-a sastoji se u kombiniranju sposobnosti neizrazitog donošenja odluka s mogućnošću izučavanja koju pruža neuronska mreža, da bi se tako prikazala dinamika nelinearnog sustava. ANFIS se može izraditi kao petoslojna mreža višeslojnih perceptrona (engl. *multilayer perceptron* – MLP) koja je prikazana na slici 32., [99]. Na toj slici krug označava fiksni čvor, a pravokutnik označava adaptivni čvor.



Slika 32. Arhitektura ANFIS mreže, ilustracija autora temeljem [99]

Na primjeru jednostavne ANFIS mreže Sugeno tipa prve razine s dvije ulazne vrijednosti (x,y) i jednom izlaznom vrijednošću (z) vrijede sljedeća pravila:

- Pravilo 1 *Ako je x jednak A_1 i y jednak B_1 , tada je $f_1 = p_1x + q_1y + r_1$*
Pravilo 2 *Ako je x jednak A_2 i y jednak B_2 , tada je $f_2 = p_2x + q_2y + r_2$*

ANFIS mreža sastoji se od pet prikazanih slojeva i organizirana je kroz pet slojeva, kako je prikazano u tablici 32.

Tablica 32 Slojevi ANFIS mreže [99], [101], [102]

Sloj 1	<p>Na prvom sloju dvije tipične ulazne vrijednosti X i Y se unose u dva ulazna čvora, koji nakon toga pretvaraju te vrijednosti u funkcije pripadnosti, gdje su X i Y ulazi, a μ_{Ai} i μ_{Bi-2} neizraziti nizovi povezani s tim čvorom. U ovom sloju svi čvorovi su adaptivnog tipa. Ai i Bi predstavljaju lingvističku varijablu koja označava stupanj pripadnosti određenog ulaza neizrazitom skupu (npr. malo, srednje, veliko) koja je pridružena funkciji pripadnosti ovog čvora.</p> $O_i^1 = \mu_{Ai}(x), i = 1,2$ $O_i^1 = \mu_{Bi-2}(y), i = 1,2$
--------	--

Sloj 2	<p>U ovom sloju svaki čvor je fiksni čvor, umnožava ulazne signale, te se izlaz O_i^2 čvora i izračunava pomoću formule:</p> $O_i^2 = W_i = \mu_{Ai}(x) * \mu_{Bi}(y), i = 1,2$ <p>Koriste se neizraziti operatori, te se koristi operator I (engl. <i>AND</i>) kako bi se fazificirao ulaz. Pridjeljuje im se oznaka π koja označava da je riječ o jednostavnom množitelju (engl. <i>single multiplier</i>).</p>
Sloj 3	<p>Treći sloj sadrži fiksne čvorove N, a u ovom sloju se umnošci iz prethodnog sloja uprosječaju. Svaki i-ti čvor računa udjel aktivacijske vrijednosti i-tog pravila u sumi svih aktivacijskih vrijednosti pravila kojima raspolaže ANFIS algoritam. Ovaj sloj naziva se normalizirana aktivacijska vrijednost. (engl. <i>normalised firing strenghts</i>).</p> $O_i^3 = W_i = \frac{w_1}{w_1 + w_2}, i = 1,2$
Sloj 4	<p>U ovom sloju svi su čvorovi adaptivni. Izlazna vrijednost iz svakog čvora je umnožak vrijednosti normalizirane jačine bljeska iz prethodnog sloja i polinomima prvog reda (za Sugeno model prvog reda). U ovom sloju čvor i izračunava doprinos i-tog pravila u izlaznoj funkciji modela, koja se definiran na osnovu metode prvog reda kao:</p> $O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), i = 1,2$ <p>Pri čemu se \bar{w}_i definira kao izlaz iz sloja 3, a p_i, q_i, r_i kao nizovi parametara.</p>
Sloj 5	<p>U ovom se sloju nalazi samo jedan čvor, odnosno jedan sloj i on služi za izračun težinskog globalnog izlaznog podatka sustava pomoću formule:</p> $O_i^5 = \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$

Za učenje ANFIS modela moguće je koristiti dva algoritma za učenje. Prvi algoritam za učenje koristi metodu povratnog rasprostiranja (engl. *backpropagation*), a drugi je hibridni algoritam koji koristi kombinaciju metoda povratnog rasprostiranja i metodu najmanjih kvadrata (engl. *least squares method*). Postupkom učenja određuju se parametri adaptivne mreže, pri čemu se mreža adaptira korištenjem uzorka temeljem poznatih vrijednosti ulaznih i izlaznih veličina. Procesom učenja određuje se struktura ANFIS modela, ukupan broj čvorova, vrsta poveznica te težinski koeficijenti [99], [101]–[104].

Proces učenja je definiran na sljedeći način. Adaptivnoj mreži se prezentira jedan ulazni element skupa podataka za učenje, a potom ona prema definiranim inicijalnim matricama težinskih koeficijenata izračunava vlastiti izlazni rezultat. Dobiveni izlazni rezultat uspoređuje se s izlazom elementa skupa podataka koji se koristi za učenje mreže. Analizira se razlika između ta dva broja, te se računa greška slaganja, koja se može definirati kao stupanj podudaranje te dvije veličine. Mreži se potom prezentiraju jedan po jedan element iz skupa podataka za učenje, sukladno ponašanju greške slaganja. Slijedi korak u kojem se modificiraju matrice težinskih koeficijenata koje se potom koriste za izbor parametara funkcija pripadnosti. Potom se odvija proces u kojem se prezentiraju svi elementi skupa podataka za učenje, a koji nosi naziv iteracija (engl. *epoch*) epoha. Proces učenja traje sve dok su greške neslaganja između vrijednosti izlaza skupa podataka za učenje i izlaza mreže statistički prihvatljive, odnosno kada ih se može definirati kao da su slučajnog karaktera [99], [101]–[104].

4. MODEL INDEKSA URBANE MOBILNOSTI

U ovom poglavlju definiran je model indeksa urbane mobilnosti zasnovan na tehnologijama umjetne inteligencije. Rezultat modela je (parcijalni) indeks urbane mobilnosti koji je definiran kao rezultat fuzije pokazatelja mobilnosti, koji opisuju pojave koje su rezultat mobilnosti, ili na njih utječu. Dakle, u prethodnim koracima su temeljem informacija iz podskupa zapisa za naplatu telekomunikacijskih usluga, koji se koriste u javnim pokretnim komunikacijskim mrežama, identificirani pokazatelji koji se koriste u opisivanju urbane mobilnosti. Pokazatelji su broj putovanja, trajanje putovanja i udaljenost. Pritom se pokazatelj broja putovanja odnosi na broj kretanja između pojedinih urbanih područja (O-D matrica) u odgovarajućem vremenskom okviru te predstavlja zbroj svih zabilježenih kretanja svih korisnika između pojedinih urbanih područja u odgovarajućem vremenskom okviru. Pokazatelj trajanja putovanja odnosi se na trajanje svakog pojedinog putovanja u promatranom vremenskom okviru. Pokazatelj udaljenosti koristi se kao aproksimacija prijednog puta, pri čemu se odnosi na udaljenost koju je korisnik prevalio na putovanju između pojedinih urbanih područja, odnosno udaljenost između izvora i odredišta putovanja, a u naravi je euklidska udaljenost između parova baznih stanica na kojima je putovanje ostvareno.

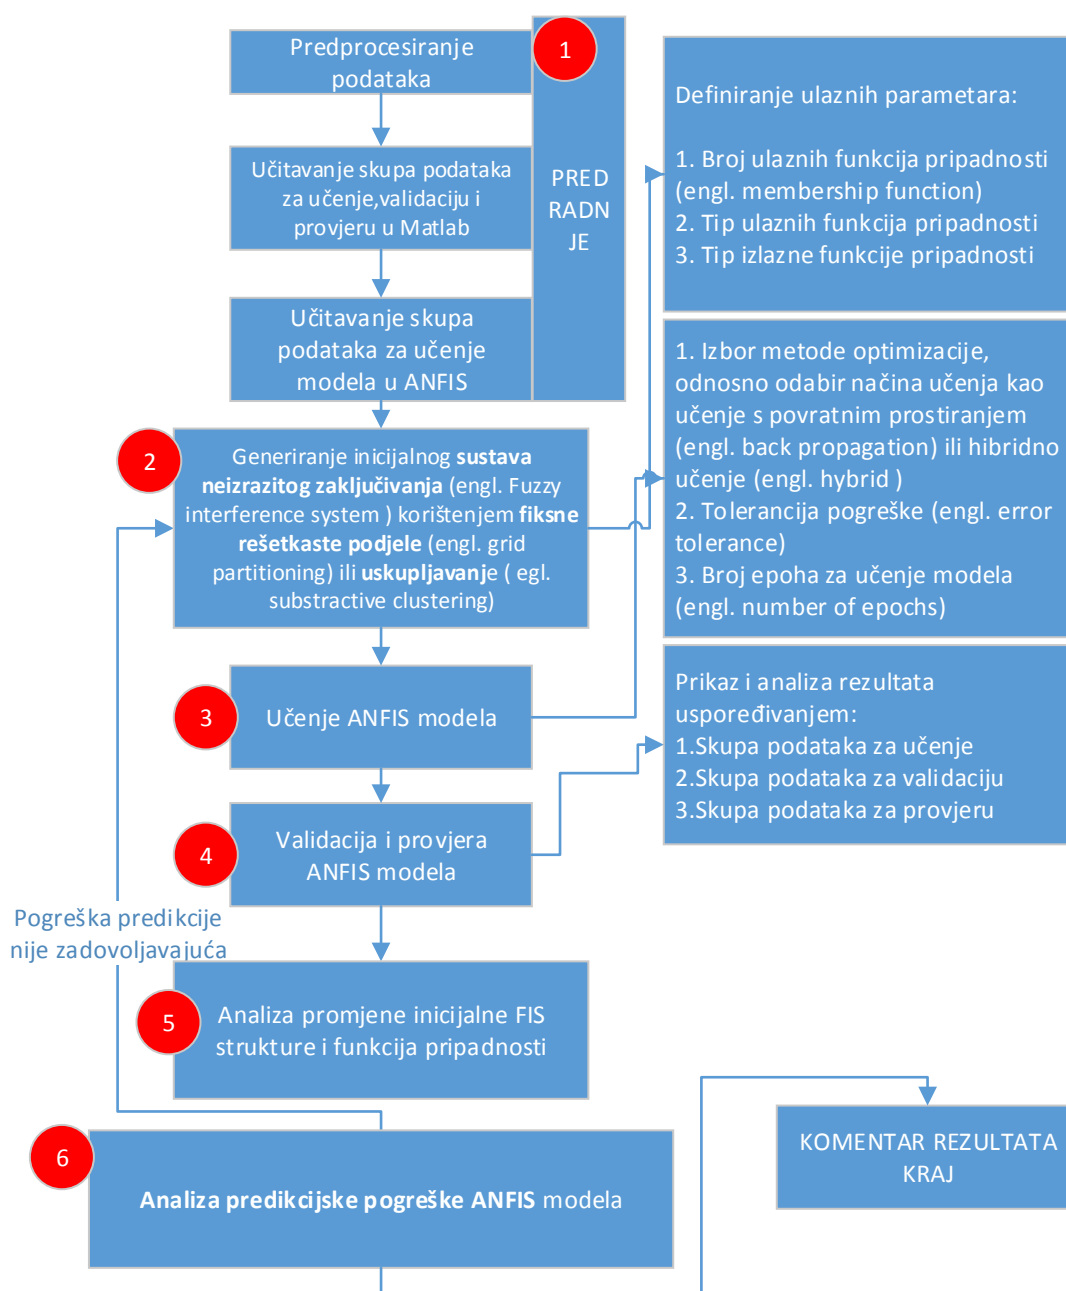
Međutim, kako bi se definirala veza između pojedinih pokazatelja i indeksa urbane mobilnosti, odnosno kako bi se definirale njihove međuovisnosti, bilo je potrebno uspostaviti bazu pravila, u svrhu dobivanja poveznice između utjecaja pojedinih pokazatelja na formiranje indeksa urbane mobilnosti. Baza pravila je prikupljena anketiranjem eksperata, koji su kroz skup pitanja definirali kako i u kojoj mjeri kombinacija vrijednosti pojedinih pokazatelja urbane mobilnosti utječe na mobilnost. Odgovori eksperata korišteni su kao ulazni podatak za formiranje pravila modela neizrazitog zaključivanja. Za modeliranje je korišten adaptivni neuro-neizraziti sustav zaključivanja (ANFIS), koji kombinira tehniku strojnog učenja i neizrazitu logiku kako bi pretvorio dane ulazne podatke u odgovarajuće izlazne vrijednosti, odnosno u kojem se funkcije pripadnosti generiraju korištenjem metoda učenja karakterističnih za neuronske mreže. Definiran je model Sugeno tipa prvog reda neizrazitog zaključivanja zasnovan na neuronskim mrežama. Od 32 testirana sustava neizrazitog zaključivanja, izabran je onaj koji će se koristiti za definiranje i razvoj modela indeksa urbane mobilnosti. Na ovaj način, generira se veličina koju koristimo u svrhu procjene mobilnosti. Rezultat modela jest procjena urbane mobilnosti za odgovarajući par urbanih područja (parcijalni indeks urbane

mobilnosti), koja se potom u postupku procjene urbane mobilnosti koristi za izračun indeksa urbane mobilnosti cjelokupne urbane aglomeracije.

4.1. Razvoj i validacija modela

Za modeliranje modela neizrazitog zaključivanja ANFIS tipa koristi se odgovarajući programski paket (*Neuro Fuzzy Toolbox*) unutar programskog alata Matlab. Početni korak u ovom postupku jest obrada podataka dobivenih anketom, koji se koriste kao referentna baza znanja za učenje modela. Modeliranje započinje učitavanjem tih skupova, odnosno skupa podataka za učenje, validaciju i provjeru modela u odgovarajuće programsko okruženje – Matlab. Potom slijedi pokretanje programskog modula ANFIS za modeliranje ANFIS sustava te učitavanje skupa podataka za učenje modela. Zatim se generira inicijalni sustav neizrazitog zaključivanja (engl. *Fuzzy inference system*) korištenjem fiksne rešetkaste podjele (engl. *grid partitioning*) ili uskupljavanjem (engl. *subtractive clustering*). U ovom se koraku odvija i definiranje ulaznih parametara kroz broj ulaznih funkcija pripadnosti (engl. *membership function*), tip ulaznih funkcija pripadnosti i tip izlaznih funkcija pripadnosti. Slijedi učenje ANFIS modela i izbor metode optimizacije, odnosno odabir načina učenja, kako je to prethodno opisano. Slijedi određivanje tolerancije pogreške (engl. *error tolerance*) i određivanje broja epoha za učenje modela (engl. *number of epochs*). Sljedeći korak jest validacija i provjera ANFIS modela te prikaz i analiza rezultata međusobnim uspoređivanjem izlaznih rezultata na temelju skupa podataka za učenje, skupa podataka za validaciju i skupa podataka za provjeru modela. Nakon ovog koraka moguće su promjene u inicijalnoj strukturi sustava neizrazitog zaključivanja (FIS) i funkcijama pripadnosti, tako da slijedi analiza tih komponenti, jer vrijednosti koje su definirane nakon procesa učenja predstavljaju konačne verzije koje će se koristiti u svrhu procjene urbane mobilnosti. Slijedi pohrana izlaznih vrijednosti iz skupa za učenje i skupa za validaciju modela te analiza predikcijske pogreške ANFIS modela korištenjem metode korijena srednjeg kvadrata pogreške (engl. RMSE – *Root Mean Squared Error*). Ukoliko je rezultat analize predikcijske pogreške ANFIS modela zadovoljavajući, modeliranje je završeno, a ukoliko pogreška nije prihvatljiva, cijeli postupak se vraća na korak

generiranja inicijalne FIS strukture. Hodogram modeliranja ANFIS modela prikazan je na slici 33.



Slika 33. Hodogram modeliranja ANFIS modela

4.1.1. Korak 1: Priprema podataka

Podaci koji pokazuju odnos vrijednosti pokazatelja mobilnosti i ocjene mobilnosti prikupljeni su putem ankete. Ispitanici su imali na raspolaganju po tri deskriptivne vrijednosti

iz skupa od po tri pokazatelja, čemu je bilo potrebno pridružiti ocjenu mobilnosti u jednoj od šest deskriptivnih kategorija. Deskriptivne vrijednosti pokazatelja su imale zamjenske numeričke vrijednosti u intervalu od [1,3], dok procjena mobilnosti ima zamjenske numeričke vrijednosti u intervalu od [1,6]. Primjer dijela odgovorenog upitnika s vrijednostima iz anketa je prikazan na slici 34., a primjer dijela odgovorenog anketnog upitnika u kojem su deskriptivne vrijednosti zamijenjene numeričkim varijablama dâan je na slici 35.

Rb.	Broj putovanja	Trajanje putovanja	Udaljenost	Procjena mobilnosti
1	Mali broj putovanja	Kratko trajanje putovanja	Mala udaljenost	Visoka mobilnost
2	Mali broj putovanja	Kratko trajanje putovanja	Srednja udaljenost	Viša srednja mobilnost
3	Mali broj putovanja	Kratko trajanje putovanja	Velika udaljenost	Niža srednja mobilnost
4	Mali broj putovanja	Srednje trajanje putovanja	Mala udaljenost	Niža srednja mobilnost
5	Mali broj putovanja	Srednje trajanje putovanja	Srednja udaljenost	Niska mobilnost

Slika 34. Primjer dijela odgovorenog anketnog upitnika sa deskriptivnim vrijednostima

Rb.	Broj putovanja	Trajanje putovanja	Udaljenost	Procjena mobilnosti
6	1	2	3	2
7	1	3	1	5
8	1	3	2	4
9	1	3	3	3
10	2	1	1	4
11	2	1	2	3
12	2	1	3	2
13	2	2	1	5
14	2	2	2	4
15	2	2	3	3

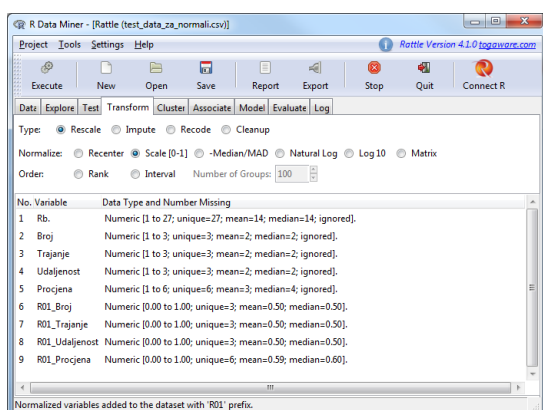
Slika 35. Primjer dijela odgovorenog anketnog upitnika u kojem su deskriptivne vrijednosti zamijenjene numeričkim varijablama

Obzirom da su podaci u različitim rasponima, provedena je njihova normalizacija. Uobičajeno je da se skup numeričkih vrijednosti normalizira tako da se od svih vrijednosti, u svim primjerima skupa podataka, oduzme minimalna vrijednost tog atributa, a dobivena vrijednost podijeli razlikom maksimalne i minimalne vrijednosti atributa (engl. *range*). Tako dobivene vrijednosti imaju isti oblik distribucije, a sve vrijednosti nalaze se u rasponu od 0 do 1. Ta je operacija poželjna, a ponekad i nužna pri modeliranju neuronskim mrežama ili stvaranju regresijskih modela [105], [106]. Normalizacija podataka je izvršena u alatu za statističku obradu i analizu podataka R, odnosno u njegovom podpaketu Rattle. Podaci se korištenjem programskog paketa Rattle (slika 36.), nakon normalizacije, pripremaju na način da se ukupni skup podataka dijeli na skup za učenje, validaciju i provjeru modela. Primjer vrijednosti podataka prije i nakon normalizacije dâan je na slici 38. Od ukupnog skupa podataka 70 % podataka je namijenjeno učenju modela, 15 % je namijenjeno provjeri modela i 15 % je namijenjeno validaciji mreže, što je vidljivo na slici 37. Po izvršenoj normalizaciji i podjeli podataka u skupove, oni se mogu koristiti za modeliranje adaptivnog neuro-neizrazitog sustava zaključivanja (engl. *adaptive neuro-fuzzy inference system* – ANFIS) kao neizrazitog sustava u kojem se funkcije pripadnosti generiraju korištenjem metoda učenja karakterističnih za neuronske mreže.

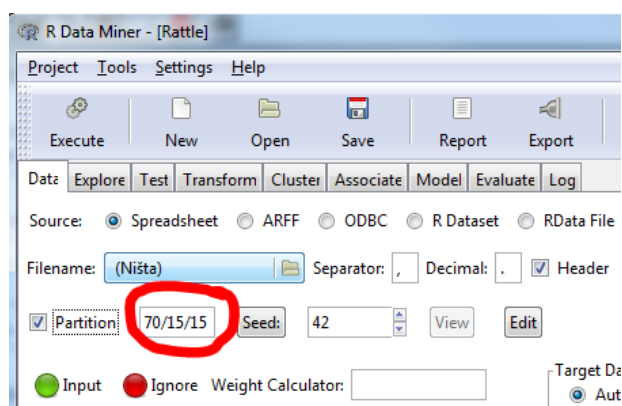
Od ukupnog broja parova podataka prikupljenih anketom (36 anketnih upitnika po 27 pitanja) generirano je ukupno 972 para podataka (engl. *data pairs*). Od tog broja, za učenje se koristi 654 para podataka, a za validaciju i za provjeru po njih 160. Broj podataka za svaku pojedinu fazu prikazan je u tablici 33. Osnovni skup podatka na podskupove je podijeljen korištenjem metode nasumičnog izbora.

Tablica 33. Broj parova podataka za pojedinu fazu modeliranja

Ukupan broj parova podataka	Broj parova podataka za učenje modela	Broj parova podataka za validaciju modela	Broj parova podataka za provjeru modela
972	654	160	160



Slika 36. Normalizacija podataka u potpaketu Rattle



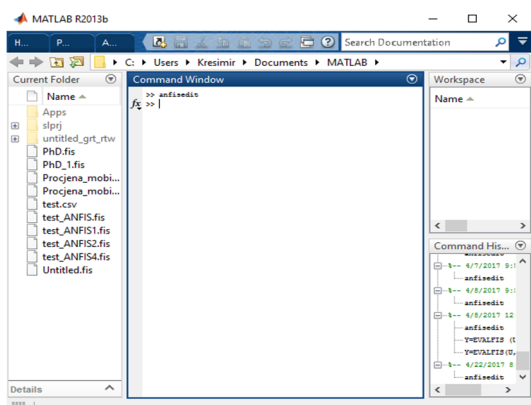
Slika 37. Podjela podataka na skup za učenje, validaciju i provjeru modela

	Broj_Putovanja	Trajanje_putovanja	Udaljenost	Ocjena_mobilnosti	R01_Broj_Putovanja	R01_Trajanje_putovanja	R01_Udaljenost	R01_Ocjena_mobilnosti
1	1	1	1	6	0.3333333	0.3333333	0.3333333	1
2	1	1	2	5	0.3333333	0.3333333	0.6666667	0.8333333
3	1	1	3	5	0.3333333	0.3333333	1	0.8333333
4	1	2	1	4	0.3333333	0.6666667	0.3333333	0.6666667
5	1	2	2	4	0.3333333	0.6666667	0.6666667	0.6666667
6	1	2	3	5	0.3333333	0.6666667	1	0.8333333
7	1	3	1	3	0.3333333	1	0.3333333	0.5
8	1	3	2	4	0.3333333	1	0.6666667	0.6666667
9	1	3	3	4	0.3333333	1	1	0.6666667
10	2	1	1	5	0.6666667	0.3333333	0.3333333	0.8333333
11	2	1	2	5	0.6666667	0.3333333	0.6666667	0.8333333

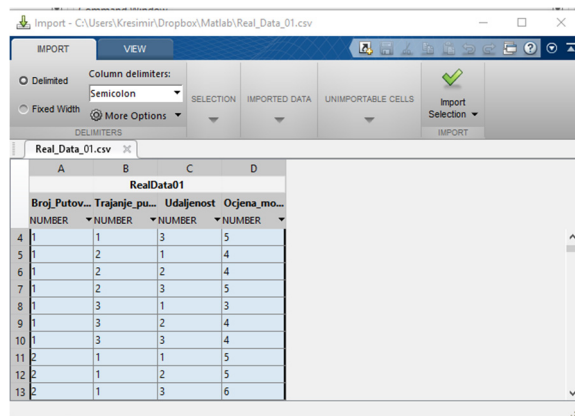
Slika 38. Primjer vrijednosti podataka prije (četiri kolone s lijeve strane) i nakon normalizacije (četiri kolone s desne strane)

Modeliranje ANFIS-a odvija se u sklopu programskog alata MATLAB. MATLAB je programski jezik i interaktivna je okolina za numeričko i matricno računanje, te za vizualizaciju i programiranje. Naziv je nastao kao kratica od engleskih riječi MATrix LABoratory. Matlab

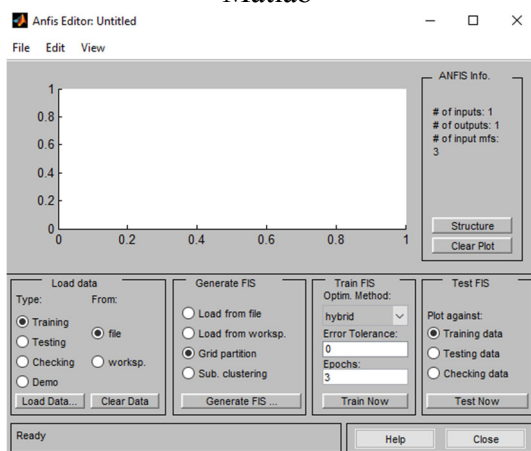
se koristi kao alat za analizu podataka, izradu algoritama, modeliranje i programiranje [107]. Sučelje programskog alata Matlab prikazano je na slici 39. U sklopu programskog alata Matlab, dostupan je programski modul ANFIS koji kao dio *Fuzzy Logic Toolbox* paketa, omogućuje formiranje ekspertnog sustava neizrazite logike Sugeno tipa temeljem dostupnih ulaznih i izlaznih podataka koji se koriste za učenje, validaciju i provjeru modela. Detaljniji opis rada ANFIS modela dan je u poglavlju 3.4.2, a sučelje alata prikazano je na slici 41.



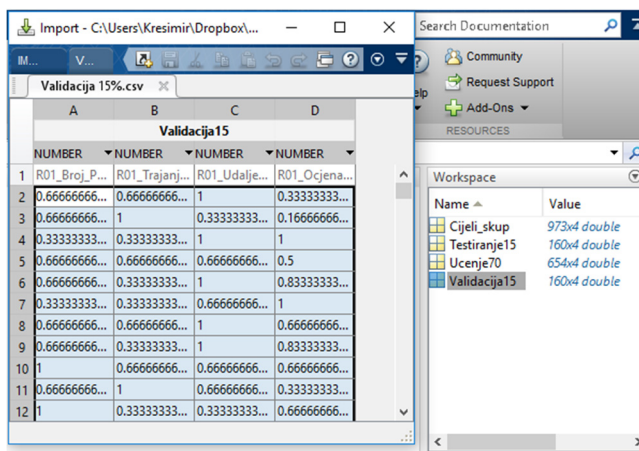
Slika 39. Sučelje programskog alata Matlab



Slika 40. Učitavanje podataka



Slika 41. Sučelje za ANFIS u programskom alatu Matlab



Slika 42. Učitavanje podataka po skupovima

Podaci se učitavaju u tablicu koja ima četiri stupca i odgovarajući broj redaka. Skupovima podataka dodjeljuju se imena sukladno njihovoj namjeni (Učenje, Validacija, Provjera). Prikaz učitanih podataka dan je na slici 40. Učitavanje podataka po skupovima prikazano je na slici 42.

4.1.2. Korak 2: Generiranje inicijalnog sustava neizrazitog zaključivanja

Nakon što je završena pripremna radnja i procedura učitavanja podataka za učenje, validaciju i provjeru modela, slijedi generiranje inicijalnog sustava neizrazitog zaključivanja (engl. *Fuzzy interference system*) korištenjem fiksne rešetkaste podjele (engl. *grid partitioning*). Fiksna rešetkasta podjela odnosi se na podjelu podatkovnog prostora u pravokutne rešetkaste elemente (engl. *grid*), koji ovise o broju funkcija pripadnosti i njihovoj vrsti. Broj pravila se povećavanjem ulaznih varijabli povećava eksponencijalno, tako da ukoliko postoji m funkcija pripadnosti i n ulaznih varijabli, tada je broj neizrazitih pravila m^n . Stoga je korištenje fiksne rešetkaste podjele ograničeno samo na primjene gdje postoji mali broj ulaznih varijabli (manje od 6), što rezultira i manjim zahtjevima na računalne resurse kod simulacije [108]. Primjena fiksne rešetkaste podjele za sustave s malim brojem funkcija pripadnosti osigurava malu grešku predikcije, te je izabrana za korištenje u ovom modelu.

Inicijalni sustav definira početne postavke funkcija pripadnosti, koje se mogu promijeniti nakon provođenja učenja kao rezultat učenja, a koje slijedi u koraku broj 7.

U ovom koraku slijedi definiranje ulaznih parametara:

1. Broj ulaznih funkcija pripadnosti (engl. *membership function*),
2. Tip ulaznih funkcija pripadnosti,
3. Tip izlazne funkcije pripadnosti.

Broj ulaznih funkcija pripadnosti definiran je brojem ulaznih varijabli. U ovaj model ulaze tri ulazne varijable i to:

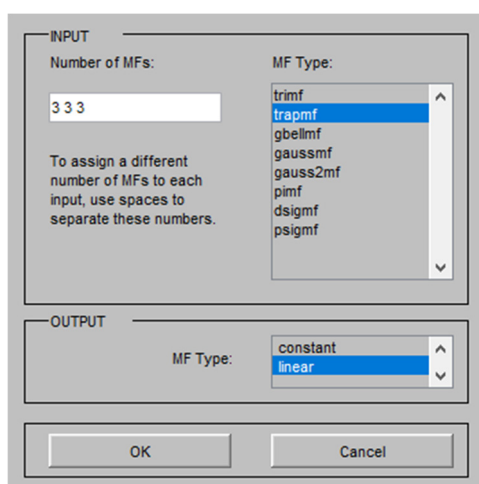
1. Broj putovanja u intervalu $[0,1]$,
2. Trajanje putovanja $[0,1]$,
3. Udaljenost $[0,1]$.

Neizrazitom skupu pojedine neizrazite varijable potom se dodjeljuje određeni oblik funkcije pripadnosti unutar skupa. Oblici funkcija pripadnosti mogu biti različiti, a najčešće su trapezoidni, trokutasti, funkcija S-tipa, itd. Izbor funkcija pripadnosti odvija se temeljem sljedećeg procesa [90], [91], [93]–[97]. U prvom koraku se za svaki neizraziti skup definira tzv. karakteristična vrijednost, odnosno vrijednost koja najbolje odražava neizrazito učenje skupa. Tipičnoj vrijednosti svakog neizrazitog skupa dodjeljuje se stupanj pripadnosti $\mu = 1$. Zatim se za svaki ostali neizraziti skup identificira ono mjesto gdje susjedni neizravni skup ima najveći

stupanj pripadnosti $\mu = 1$, te mu se pridjeljuje stupanj pripadnosti $\mu = 0$. Potom se povezuju linijom točke za svaki pojedini skup, pri čemu se jedna točka nalazi u sredini $\mu = 1$, a točke sa stupnjem pripadnosti skupu $\mu = 0$, lijevo i desno od nje (osim kod skupova koji se nalaze na granici intervala). Ti skupovi se odnose na krajnji desni i krajnji lijevi skup, te oni nemaju susjedne skupove s obje strane, već samo s jedne. Za njih vrijedi pravilo da za vrijednost neizrazitog skupa iza točke gdje skup ima definiran stupanj pripadnosti $\mu = 1$, skup također poprima vrijednost stupnja pripadnosti $\mu = 1$. Lijevo rubni neizraziti skup tada će poprimiti oblik funkcije pripadnosti Z-tipa, a rubni desni neizraziti skup će poprimiti oblik funkcije pripadnosti S-tipa. Dakle, u ovom koraku svakoj se ulaznoj varijabli pridodaje odgovarajuća funkcija pripadnosti, definira se broj točaka prijeloma za svaku ulaznu funkciju. Za svaku se funkciju definira raspon djelovanja. Također, definira se tip izlazne funkcije pripadnosti. Tip funkcije pripadnosti koji je moguće koristiti prikazan je u tablici 34. Izbor funkcije pripadnosti obavlja se putem izbornika prikazanog na slici 43.


Tablica 34. Funkcije pripadnosti [107]

Funkcija pripadnosti	Opis
Trimf	Funkcija pripadnosti trokut
Tramf	Funkcija pripadnosti trapez
Gbellmf	Funkcija pripadnosti tipa bell
Gaussmf	Funkcija pripadnosti Gaussovog tipa
gauss2mf	Funkcija pripadnosti dvoparametarskog gaussovog tipa
Pimf	Funkcija pripadnosti π
Dsigmf	Funkcija pripadnosti kao razlika sigmoidalnih funkcija
Psigmf	Funkcija pripadnosti kao produkt sigmoidalnih funkcija



Slika 43. Izbor funkcije pripadnosti

Ulazne veličine pretvorene su u neizrazite skupove na način kako je definirano u nastavku u tablici 35. za ulaznu varijablu „Broj putovanja“, u tablici 36. za ulaznu varijablu „Trajanje putovanja“, te u tablici 37 za varijablu „Udaljenost“. Svako od njih je pridijeljena funkcija oblika tipa trapez i odgovarajući intervali. Obzirom da su funkcije pripadnosti tipa trapez, interval funkcija pripadnosti predstavljen je koordinatom vrha trapeza na x osi, kao što je prikazano na slici 44. Koordinate vrha trapeza na x osi označene su slovima A, B, C i D, a interval se zapisuje kao [A B C D].



Slika 44. Prikaz opisa intervala funkcije pripadnosti tipa trapez

Tablica 35. Ulazna varijabla „Broj putovanja“ i pripadajući neizraziti skupovi u inicijalnom modelu neizrazitog zaključivanja

Ulazna varijabla	Neizraziti skup	Interval	Grafički prikaz
Broj putovanja	Mali broj putovanja	$[-0,35 -0,15$ $0,$ $15 0,35]$	
	Srednji broj putovanja	$[0,15 0,35$ $0,65 0,85]$	
	Veliki broj putovanja	$[0,65 0,85$ $1,15 1,35]$	

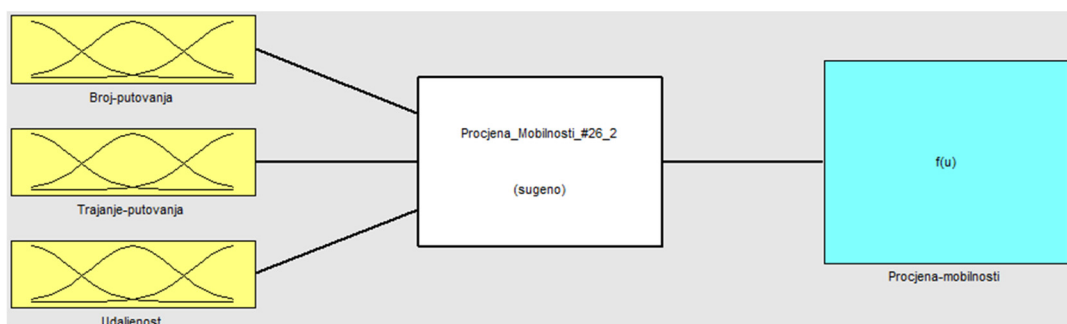
Tablica 36. Ulazna varijabla „Trajanje putovanja“ i pripadajući neizraziti skupovi u inicijalnom modelu neizrazitog zaključivanja

Ulazna varijabla	Neizraziti skup	Interval	Grafički prikaz
Trajanje putovanja	Kratko trajanje putovanja	$[-0,35 -0,15$ $0,$ $15 0,35]$	
	Srednje trajanje putovanja	$[0,15 0,35$ $0,65 0,85]$	
	Dugo trajanje putovanja	$[0,65 0,85$ $1,15 1,35]$	

Tablica 37. Ulazna varijabla „Udaljenost“ i pripadajući neizraziti skupovi u **inicijalnom modelu neizrazitog** zaključivanja

Ulazna varijabla	Neizraziti skup	Interval	Grafički prikaz
Udaljenost	Mala udaljenost	$[-0,35 \ -0,15 \ 0, \ 15 \ 0,35]$	
	Srednja udaljenost	$[0,15 \ 0,35 \ 0,65 \ 0,85]$	
	Velika udaljenost	$[0,65 \ 0,85 \ 1,15 \ 1,35]$	

U ovom koraku definirana je i izlazna funkcija pripadnosti koja će pokazati rezultat modela za svaki od pojedinačnih scenarija. Vrijednost izlazne funkcije pripadnosti za svaki scenarij, odnosno za svako pravilo iznosi nula prije provođenja procesa učenja mreže, a vrijednost se funkciji pridjeljuje po završetku procesa učenja. Također, po završetku procesa učenja moguće su promjene u intervalima i funkcijama pripadnosti ulaznih varijabli. Rezultat učenja bit će točno definirano područje funkcije prekrivanja izlazne funkcije za svako pravilo u bazi. Grafički prikaz inicijalnog modela indeksa urbane mobilnosti dan je na slici 45.



Slika 45. Grafički prikaz inicijalnog modela indeksa urbane mobilnosti

4.1.3. Korak 3: Učenje ANFIS modela


U ovom koraku odvija se proces učenja ANFIS modela. Prije početka procesa učenja potrebno je definirati:

1. Metodu optimizacije, odnosno odabir načina učenja između učenja s povratnim prostiranjem (engl. *backpropagation*) ili hibridnog učenje (engl. *hybrid*),
2. Toleranciju pogreške (engl. *error tolerance*),
3. Broj epoha za učenje modela (engl. *number of epochs*).

Kod definiranja sustava za zaključivanje ANFIS modela moguće je koristiti dvije metode učenja ANFIS modela. Prva metoda za učenje koristi metodu povratnog rasprostiranja (engl. *backpropagation*), druga metoda predstavlja hibridnu metodu koja koristi kombinaciju metoda povratnog rasprostiranja i metodu najmanjih kvadrata (engl. *least squares method*). Postupkom učenja određuju se parametri adaptivne mreže, pri čemu se mreža adaptira korištenjem uzorka temeljem poznatih vrijednosti ulaznih i izlaznih veličina. Procesom učenja određuje se struktura ANFIS modela, ukupan broj čvorova, vrsta poveznica te težinski koeficijenti [99], [101]–[104]. Proces učenja je definiran na sljedeći način. Adaptivnoj mreži se prezentira jedan ulazni element skupa podataka za učenje, koja prema definiranim inicijalnim matricama težinskih koeficijenata izračunava vlastiti izlazni rezultat. Dobiveni izlazni rezultat uspoređuje s izlazom elementa skupa podataka koji se koristi za učenje mreže. Analizira se razlika između ta dva broja, te se računa greška slaganja, koja se može definirati kao stupanj podudaranja te dvije veličine. Mreži se potom prezentiraju jedan po jedan element skupa podataka za učenje sukladno ponašanju greške slaganja. Slijedi korak u kojem se modificiraju matrice težinskih koeficijenata koje se potom koriste za izbor parametara funkcija pripadnosti. Potom se odvija proces u kojem se prezentiraju svi elementi skupa podataka za učenje, a koji nosi naziv iteracija ili (engl. *epoch*) epoha. Proces učenja traje sve dok pogreška predikcije (između ulaznih vrijednosti skupa podataka za učenje i izlaza mreže) ne postane statistički prihvatljiva, odnosno kada se može definirati kao da je slučajnog karaktera [99], [101]–[104].

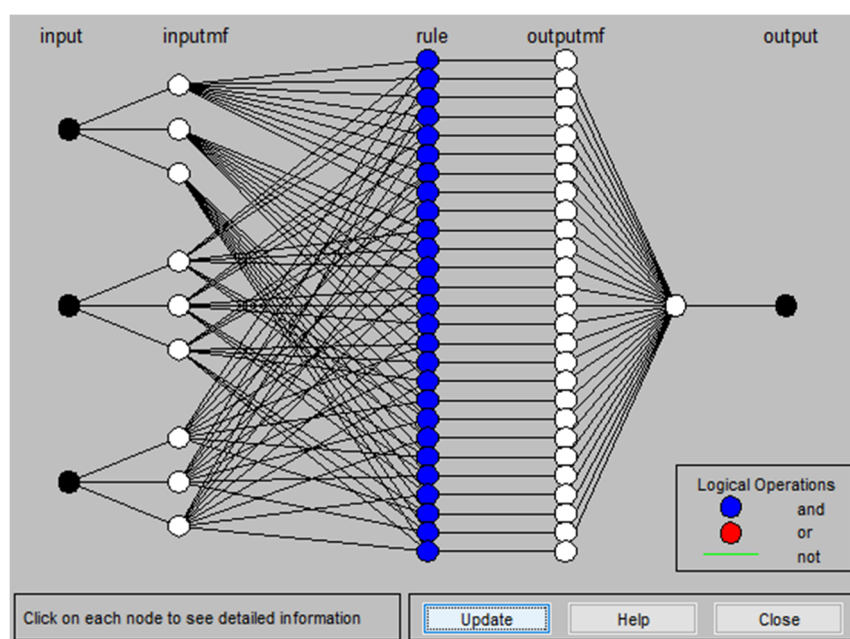
Svi sustavi neizrazitog zaključivanja učeni su metodom povratnog prostiranja i hibridnom metodom. Za svaki od sustava neizrazitog zaključivanja definirana su po tri scenarija, tako da je u prvom scenariju broj epoha za učenje bio tri (predefinirana postavka), u

drugom je broj epoha za učenje bio 10, a u trećem je broj epoha za učenje bio 100. Temeljem analize rezultata, koja je opisana u koraku šest, zaključeno je da će se u ovoj disertaciji koristiti hibridna metoda učenja, u kojoj je definirana nulta tolerancija pogreške i u kojoj se učenje odvija kroz tri epohe. Struktura izabranog ANFIS modela prikazana je na slici 47. Postupak učenja ANFIS modela korištenjem skupa podataka za učenje prikazan je na slici 46. Pogreška učenja definira se kao razlika između vrijednosti izlazne varijable originalnog i nemodificiranog skupa podataka koji je korišten za učenje te razlike između vrijednosti izlazne varijable iz sustava neizrazitog zaključivanja korištenjem istog skupa ulaznih podataka. Pogreška učenja računa se kao srednji korijen kvadratne pogreške (RMSE) za svaki korak, odnosno epohu učenja. Tijekom učenja mreže, na grafikonu se prikazuje vrijednost pogreške u ovisnosti o svakoj epohi učenja. Primjer prikaza smanjenja pogreške tijekom provođenja učenja mreže kroz 100 epoha za sustav neizrazitog zaključivanja pod rednim brojem 27 (postavke: funkcije pripadnosti ulaznih varijabli su tipa trapez, učenje s povratnim prostiranjem, izlazna funkcija linearna, broj epoha 100), prikazan je na slici 46.

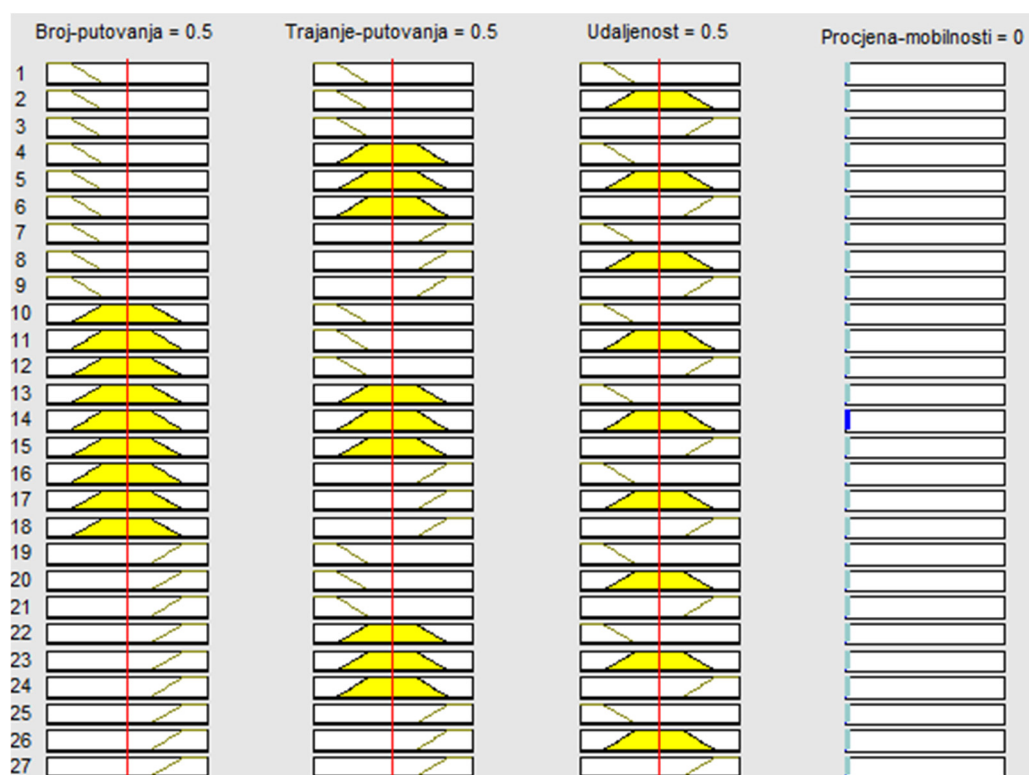


Slika 46. Pogreška učenja u ovisnosti o broju epoha za sustav neizrazitog zaključivanja broj 27

Rezultat učenja je mreža s 78 čvorova, koja ima 108 linearnih parametara, zatim 36 nelinearnih parametara, odnosno ukupno 144 parametra. Za učenje modela korišteno je 654 parova podataka, a za validaciju je korišteno 160 parova podataka. Sustav je rezultirao bazom pravila koja sadrži 27 (3^3) pravila. Model je opisan s 27 pravila, od kojih svaki ima svoj interval izlaznih vrijednosti procjene mobilnosti, u ovisnosti o ulaznim vrijednostima parametara ulaznih varijabli. Grafički prikaz pravila prije učenja modela prikazan je na slici 48., a prikaz dijela pravila raspisanih u tekstualnom obliku dan je na slici 49.



Slika 47. Struktura ANFIS modela



Slika 48. Grafički prikaz pravila u inicijalnom modelu neizrazitog zaključivanja

```


1. If (Broj-putovanja is Mali-broj-putovanja) and (Trajanje-putovanja is Kratko-trajanje-putovanja) and (Udaljenost is Mala-udaljenost) then (Procjena-mobilnosti is out1mf1) (1)
2. If (Broj-putovanja is Mali-broj-putovanja) and (Trajanje-putovanja is Kratko-trajanje-putovanja) and (Udaljenost is Srednja-udaljenost) then (Procjena-mobilnosti is out1mf2) (1)
3. If (Broj-putovanja is Mali-broj-putovanja) and (Trajanje-putovanja is Kratko-trajanje-putovanja) and (Udaljenost is Velika-udaljenost) then (Procjena-mobilnosti is out1mf3) (1)
4. If (Broj-putovanja is Mali-broj-putovanja) and (Trajanje-putovanja is Srednje-trajanje-putovanja) and (Udaljenost is Mala-udaljenost) then (Procjena-mobilnosti is out1mf4) (1)
5. If (Broj-putovanja is Mali-broj-putovanja) and (Trajanje-putovanja is Srednje-trajanje-putovanja) and (Udaljenost is Srednja-udaljenost) then (Procjena-mobilnosti is out1mf5) (1)
6. If (Broj-putovanja is Mali-broj-putovanja) and (Trajanje-putovanja is Srednje-trajanje-putovanja) and (Udaljenost is Velika-udaljenost) then (Procjena-mobilnosti is out1mf6) (1)
7. If (Broj-putovanja is Mali-broj-putovanja) and (Trajanje-putovanja is Dugo-trajanje-putovanja) and (Udaljenost is Mala-udaljenost) then (Procjena-mobilnosti is out1mf7) (1)
8. If (Broj-putovanja is Mali-broj-putovanja) and (Trajanje-putovanja is Dugo-trajanje-putovanja) and (Udaljenost is Srednja-udaljenost) then (Procjena-mobilnosti is out1mf8) (1)
9. If (Broj-putovanja is Mali-broj-putovanja) and (Trajanje-putovanja is Dugo-trajanje-putovanja) and (Udaljenost is Velika-udaljenost) then (Procjena-mobilnosti is out1mf9) (1)
10. If (Broj-putovanja is Srednji-broj-putovanja) and (Trajanje-putovanja is Kratko-trajanje-putovanja) and (Udaljenost is Mala-udaljenost) then (Procjena-mobilnosti is out1mf10) (1)
11. If (Broj-putovanja is Srednji-broj-putovanja) and (Trajanje-putovanja is Kratko-trajanje-putovanja) and (Udaljenost is Srednja-udaljenost) then (Procjena-mobilnosti is out1mf11) (1)
12. If (Broj-putovanja is Srednji-broj-putovanja) and (Trajanje-putovanja is Kratko-trajanje-putovanja) and (Udaljenost is Velika-udaljenost) then (Procjena-mobilnosti is out1mf12) (1)
13. If (Broj-putovanja is Srednji-broj-putovanja) and (Trajanje-putovanja is Srednje-trajanje-putovanja) and (Udaljenost is Mala-udaljenost) then (Procjena-mobilnosti is out1mf13) (1)
14. If (Broj-putovanja is Srednji-broj-putovanja) and (Trajanje-putovanja is Srednje-trajanje-putovanja) and (Udaljenost is Srednja-udaljenost) then (Procjena-mobilnosti is out1mf14) (1)
15. If (Broj-putovanja is Srednji-broj-putovanja) and (Trajanje-putovanja is Srednje-trajanje-putovanja) and (Udaljenost is Velika-udaljenost) then (Procjena-mobilnosti is out1mf15) (1)
16. If (Broj-putovanja is Srednji-broj-putovanja) and (Trajanje-putovanja is Dugo-trajanje-putovanja) and (Udaljenost is Mala-udaljenost) then (Procjena-mobilnosti is out1mf16) (1)
17. If (Broj-putovanja is Srednji-broj-putovanja) and (Trajanje-putovanja is Dugo-trajanje-putovanja) and (Udaljenost is Srednja-udaljenost) then (Procjena-mobilnosti is out1mf17) (1)

```


Slika 49. Prikaz dijela pravila raspisanih u tekstualnom obliku

4.1.1. Korak 4: Validacija i provjera ANFIS modela


U ovom koraku odvija se proces validacije i provjere ANFIS modela, odnosno prikazuju se i analiziraju rezultati predikcije modela uspoređivanjem rezultata modela dobivenih na osnovi skupa podataka za učenje, skupa podataka za validaciju i skupa podataka za provjeru modela. Grafički prikaz skupa podataka za učenje prikazan je na slici 50., skupa podataka za validaciju prikazan je na slici 51., a skupa podataka za provjeru na slici 52.



Slika 50. Skup podataka za učenje



Slika 51. Skup podataka za validaciju




Slika 52. Skup podataka za provjeru

Validacija i provjera ANFIS modela uključuje dva procesa i to proces validacije modela i proces provjere modela.

Validacija modela jest proces koji se koristi za ocjenjivanje pouzdanosti zaključivanja modela. Razlika između faze učenja i faze validacije je u tom što u ovoj fazi model više ne uči, odnosno težinski koeficijenti nad vrijednostima dobiveni kao rezultat učenja se fiksiraju te se više ne mijenjaju. Takvom modelu se zatim predstavljaju novi ulazni podaci (iz skupa podataka za validaciju) koji nisu korišteni u procesu učenja modela. Od modela se tada očekuje da za predstavljen novi ulazni vektor proizvede izlaz, pri čemu se ocjenjivanje modela obavlja izračunom pogreške predikcije na način da se izračunati izlaz iz modela uspoređuje sa stvarnim izlazima. Uspješnost predikcije modela mjeri se pomoću pogreške validacije. Pogreška validacije definira se kao razlika između vrijednosti izlazne varijable originalnog i nemodificiranog skupa podataka koji je korišten za validaciju te razlike između vrijednosti izlazne varijable iz sustava neizrazitog zaključivanja korištenjem istog skupa (skup za


validaciju) ulaznih podataka. Pogreška provjere učenja računa se kao srednji korijen kvadratne pogreške (RMSE). Za potrebe validacije u odnos se stavlja skup podataka za učenje naspram skupa podataka za validaciju modela. Prosječna pogreška validacije modela (za model izabran kao optimalan u koraku 9) iznosi $0,2103$, a grafički prikaz odnosa skupa podataka za učenje i skupa podataka za validaciju modela prikazan je na slici 53.



Slika 53. Odnos skupa podataka za učenje i skupa podataka za validaciju modela

Slijedi korak provjere modela. Općenito, prilikom provjere modela uspostavljenih pomoću adaptivnih tehnika, posebnu pažnju treba obratiti na odabir podataka u skupu za provjeru, kako bi bili reprezentativni u odnosu na podatke koji su korišteni za učenje modela, ali opet i dovoljno različiti od skupa podataka za učenje modela, kako se postupak provjere ne bi učinio trivijalnim [109]. Skup podataka za provjeru koristi se za ispitivanje mogućnosti zaključivanja neizrazitog sustava u svakoj epohi učenja u odnosu na stvarni skup podataka. Skup podataka za provjeru ima isti format kao i skup podataka za učenje modela. Ukoliko je skup podataka za provjeru ispravan, pogreška provjere padat će s brojem epoha, odnosno smanjivat će se tijekom procesa učenja mreže. Svrha uvođenja provjere modela temeljem skupa parova podataka za provjeru modela jest eliminiranje pojave koja se može javiti prilikom učenja modela, kada dolazi do „prerastanja“, odnosno do prejake prilagodbe (engl. *overfitting*) skupa parova podataka za učenje. Naime, pogreška na ulazno-izlaznom skupu podataka je nakon učenja vrlo mala, a kad se na ulaz mreže dovedu novi podaci na kojima mreža nije učila (trenirala), pogreška je jako velika, odnosno mreža nema mogućnost generalizacije ili aproksimacije novih situacija. Kada se u procesu učenja počinje događati prerastanje, pogreška provjere počinje rasti [109]. Pogreška provjere definira se kao razlika između vrijednosti izlazne varijable iz originalnog i nemodificiranog skupa ulaznih podataka koji je korišten za

provjeru te razlike između vrijednosti izlazne varijable iz sustava neizrazitog zaključivanja, pri čemu je korišten isti skup (skup za provjeru) ulaznih podataka. Pogreška provjere učenja računa se kao srednji korijen kvadratne pogreške (RMSE) za svaki korak, odnosno za svaku epohu učenja. Provjera se odvija na način da se u odnos stavi skup podataka za učenje naspram skupa podataka za provjeru modela, te se potom odabiru parametri modela na temelju minimalnih pogrešaka skupa parova podataka za provjeru.



Slika 54. Odnos skupa podataka za učenje i skupa podataka za validaciju modela

Na slici 54. prikazan je odnos podataka korištenih za učenje modela i podataka korištenih za provjeru modela. Prosječna pogreška provjere modela iznosi 0,1907. Proces validacije i provjere modela proveden je za svaki sustav neizrazitog zaključivanja koji je kreiran za potrebe formiranja indeksa urbane mobilnosti, a što je detaljno opisano u koraku 10 ovog postupka. Na kraju je za uspostavu indeksa urbane mobilnosti izabran sustav neizrazitog zaključivanja koji ima najmanju pogrešku učenja modela.

4.1.2. Korak 5: Analiza promjene inicijalne FIS strukture i funkcija pripadnosti

Izbor sustava neizrazitog zaključivanja definiran je u koraku šest, a u koraku dva je definiran u svom inicijalnom obliku. Nakon završetka procesa učenja modela izgledno je da je došlo do modifikacije sustava neizrazitog zaključivanja, prvenstveno u vidu promjena u vrijednostima koje opisuju funkcije pripadnosti ulaznih i izlazne varijable. Vrijednosti intervala funkcija dobivenih u ovom koraku predstavljaju konačnu verziju intervala pojedine funkcije pripadnosti, te će ti intervali biti korišteni tijekom modeliranja procjene urbane mobilnosti. Usporedba vrijednosti intervala funkcija pripadnosti kod inicijalnog sustava neizrazitog zaključivanja, kao i usporedba vrijednosti intervala funkcija pripadnosti nakon provođenja

učenja kod izabranog sustava neizrazitog zaključivanja (sustav s rednim brojem 26), prikazan je u tablici 38.

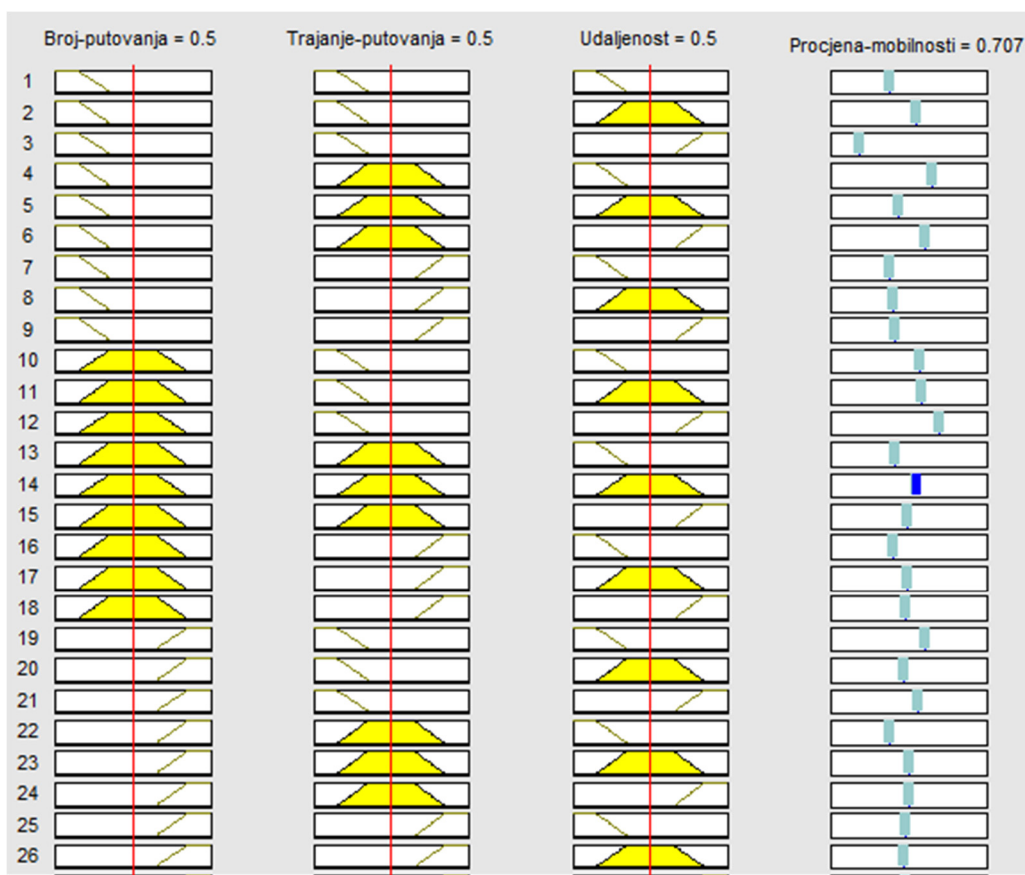
Tablica 38. Usporedba vrijednosti intervala ulaznih funkcija pripadnosti prije i poslije provođenja učenja modela

Ulazna varijabla	Neizraziti skup	Interval funkcija kod inicijalnog sustava za neizrazito zaključivanje	Interval funkcija pripadnosti nakon provođenja učenja kod izabranog sustava neizrazitog zaključivanja
Broj putovanja	Mali broj putovanja	[-0,35 -0,15 0,15 0,35]	[-0,35 -0,15 0,1512 0,361]
	Srednji broj putovanja	[0,15 0,35 0,65 0,85]	[0,1501 0,3512 0,6497 0,85]
	Veliki broj putovanja	[0,65 0,85 1,15 1,35]	[0,6473 0,8497 1,15 1,35]
Trajanje putovanja	Kratko trajanje putovanja	[-0,35 -0,15 0,15 0,35]	[-0,35 -0,15 0,1514 0,3628]
	Srednje trajanje putovanja	[0,15 0,35 0,65 0,85]	[0,1501 0,3514 0,6504 0,85]
	Dugo trajanje putovanja	[0,65 0,85 1,15 1,35]	[0,6544 0,8504 1,15 1,35]
Udaljenost	Mala udaljenost	[-0,35 -0,15 0,15 0,35]	[-0,35 -0,15 0,1507 0,3568]
	Srednja udaljenost	[0,15 0,35 0,65 0,85]	[0,1501 0,3507 0,6505 0,85]
	Velika udaljenost	[0,65 0,85 1,15 1,35]	[0,6558 0,8505 1,15 1,35]

Izlazna veličina, funkcija procjene urbane mobilnosti, temeljena je na 27 pravila neizrazitog modela zaključivanja te je sukladno tome definirana i s 27 funkcija pripadnosti. Intervali izlazne funkcije, odnosno definicije područja neizrazitih skupova prikazani su u tablici 39.

Tablica 39. Intervali izlazne funkcije u inicijalnom modelu neizrazitog zaključivanja

Naziv funkcije pripadnosti	Interval funkcije pripadnosti
Out1mf1	[-0,1402 -0,1402 -0,1402 -4,205e-07]
Out1mf2	[0,01942 0,01942 1,163 0,05826]
Out1mf3	[-0,2084 -0,2084 -0,6946 -0,6251]
Out1mf4	[0,1535 1,223 0,1535 0,4604]
Out1mf5	[0,1426 0,1583 -0,9453 0,4277]
Out1mf6	[0,03881 1,439 0,1826 0,1164]
Out1mf7	[-0,03508 -0,1781 -0,03508 -0,1052]
Out1mf8	[-0,04072 -0,1232 0,1998 -0,1222]
Out1mf9	[0,0004024 -0,09425 -0,01342 0,001207]
Out1mf10	[1,101 0,06554 0,06554 0,1966]
Out1mf11	[1,688 0,1231 0,388 0,3694]
Out1mf12	[-0,8052 -0,1714 0,1284 0,3852]
Out1mf13	[-0,1759 -0,624 -0,2187 1,216]
Out1mf14	[0,01136 -0,5246 0,4578 0,4199]
Out1mf15	[0,1799 -0,0739 -0,03145 -0,09434]
Out1mf16	[0,3004 0,09807 0,2707 0,02788]
Out1mf17	[0,08544 0,1777 0,1164 0,1323]
Out1mf18	[0,4683 0,1922 0,1922 0,5766]
Out1mf19	[0,5073 0,1721 -1,197 0,5162]
Out1mf20	[0,1958 0,1198 0,4426 0,3593]
Out1mf21	[0,2819 -1,133 0,06145 0,1843]
Out1mf22	[0,6368 -0,7401 -0,1086 0,5761]
Out1mf23	[0,3761 -0,5408 0,3809 0,3626]
Out1mf24	[0,1301 0,2336 0,004073 0,1522]
Out1mf25	[0,1106 0,16 0,1144 0,1149]
Out1mf26	[0,09158 0,1856 0,04868 0,122]
Out1mf27	[0,1106 0,16 0,1144 0,1149]



Slika 55. Grafički prikaz pravila po završetku procesa učenja modela

U ovom koraku finaliziraju se i oblici i vrijednosti pravila u bazi znanja neizrazitog modela. Vrijednosti pravila zaključivanja za sva pravila definirana sustavom neizravnog zaključivanja prikazana su na slici 55.

4.1.3. Korak 6: Analiza predikacijske pogreške ANFIS modela

U ovom koraku bit će prikazane predikacijske pogreške učenja modela za sve analizirane sustave neizrazitog zaključivanja, kao kriterija za izvor optimalnog modela. Za odabir optimalnog modela koristit će se metode za ocjenu prediktivne efikasnosti (točnosti modela). Za procjenu točnosti modela može se koristiti više metoda, od kojih su poznatije metoda srednje kvadratne pogreške (engl. *mean squared error* - *MSE*), zatim metoda korijena srednje kvadratne pogreške (engl. *root mean square error* - *RMSE*) ili normalizirani korijen

srednje kvadratne pogreške (engl. *normalized root mean square error* - *NRMSE*) [100]. Korištenjem ovih metoda se na temelju odabranih modela i originalnih vrijednosti ulaznog skupa podataka izračunavaju prognostičke vrijednosti, a potom i prognostičke pogreške. Pri tome se model s najmanjim prognostičkim pogreškama (koji zadovoljava dijagnostičku provjeru) odabire kao adekvatan. U ovoj disertaciji će se koristiti metoda korijena srednje kvadratne pogreške, kao najčešća i uobičajena metoda korištena za ove potrebe.

RMSE je mjera za razliku između vrijednosti predviđenih nekim modelom i stvarne vrijednosti koja se modelira ili procjenjuje. Razlika između te dvije vrijednosti nosi naziv rezidual. RMSE se koristi kako bi ih agregirao u jedinstvenu mjeru preciznosti predviđanja. Dakle, korijen srednje kvadratne pogreške (RMSE) je mjera ukupne pogreške. Izračunava se po formuli (30):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [i(x_i) - p.]^2} \quad (30)$$

pri čemu je:

- RMSE – srednja kvadratna pogreška procjene odabrane metode,
- $i(x_i)$ – izmjerena vrijednost odabrane varijable,
- $p(x_i)$ – procijenjena vrijednost odabrane varijable.

U ovom koraku obavlja se izbor modela analizom rezultata sustava neizrazitog zaključivanja sve dok se ne identificira optimalni s najmanjom pogreškom za učenje. Definirana su 32 sustava za neizrazito zaključivanje. Svim sustavima neizrazitog zaključivanja su pridijeljene odgovarajuće funkcije pripadnosti, definiran je oblik izlazne varijable te je definirana metoda za učenje (optimizaciju), kao i broj epoha. Prikaz izabranih kombinacija, zajedno s vrijednostima pogrešaka, dan je u tablici 40. Sustavi su se razlikovali u ovisnosti od oblika ulazne funkcije pripadnosti (funkcija pripadnosti tipa trokut, tipa trapez, tipa bell, gaussovog tipa, dvoparametarskog gaussovog tipa, funkcija pripadnosti π , funkcija pripadnosti kao razlika sigmoidalnih funkcija i funkcija pripadnosti kao produkt sigmoidalnih funkcija), zatim u ovisnosti o vrsti izlazne funkcije pripadnosti (linearna, konstantna), u ovisnosti o vrsti metode učenja (hibridno učenje, učenje s povratnim prostiranjem), kao i o broju koraka učenja

(3, 10, 100). Svaki uspostavljeni neizraziti sustav testiran je na pouzdanost korištenjem RMSE metode, pri čemu je u analizu ušla greška učenja.

Tablica 40. Prikaz rezultata greške učenja i validacije modela u ovisnosti o postavkama sustava za neizrazito zaključivanje


Redni broj FIS-a	Funkcija pripadnosti		Metoda optimizacije (učenja)	Učenje mreže (broj epoha)		
				3	10	100
	Ulazna	Izlazna		Greška učenja	Greška učenja	Greška učenja
1	Dsigmf	Konstanta	Backpropagation	0,62779	0,596169	0,17
2	Dsigmf	Konstanta	Hibridna	0,163076	0,163076	0,163076
3	dsigmf	Linearna	Backpropagation	0,623054	0,575004	0,164414
4	dsigmf	Linearna	Hibridna	0,163076	0,163076	0,163076
5	gauss2mf	Konstanta	Backpropagation	0,627839	0,59579	0,210007
6	gauss2mf	Konstanta	Hibridna	0,163076	0,163076	0,163076
7	gauss2mf	Linearna	Backpropagation	0,623117	0,57459	0,164886
8	gauss2mf	Linearna	Hibridna	0,163076	0,163076	0,163076
9	gaussmf	Konstanta	Backpropagation	0,62853	0,599231	0,17443
10	gaussmf	Konstanta	Hibridna	0,163076	0,163076	0,163076
11	gaussmf	Linearna	Backpropagation	0,624043	0,57917	0,164962
12	gaussmf	Linearna	Hibridna	0,163076	0,163076	0,163076
13	gbellmf	Konstanta	Backpropagation	0,628403	0,588783	0,175404
14	gbellmf	Konstanta	Hibridna	0,163076	0,191311	0,163076
15	gbellmf	Linearna	Backpropagation	0,623905	0,578599	0,16436
16	gbellmf	Linearna	Hibridna	0,163076	0,163076	0,163076
17	pimf	Konstanta	Backpropagation	0,627515	0,59505	0,233071
18	pimf	Konstanta	Hibridna	0,163076	0,163076	0,163076
19	pimf	Linearna	Backpropagation	0,622707	0,573577	0,16441
20	pimf	Linearna	Hibridna	0,163076	0,163076	0,163076
21	psigmf	Konstanta	Backpropagation	0,62779	0,596169	0,233187
22	psigmf	Konstanta	Hibridna	0,163076	0,163076	0,163076
23	psigmf	Linearna	Backpropagation	0,623054	0,575004	0,164414
24	psigmf	Linearna	Hibridna	0,163076	0,163076	0,163076
25	tramf	Konstanta	Backpropagation	0,627814	0,595616	0,233112
26	tramf	Konstanta	Hibridna	0,163076	0,163076	0,163076
27	tramf	Linearna	Backpropagation	0,6238	0,574327	0,16441
28	tramf	Linearna	Hibridna	0,163076	0,163076	0,163076
29	trimf	Konstanta	Backpropagation	0,628543	0,599637	0,230852
30	trimf	Konstanta	Hibridna	0,163076	0,163076	0,163076
31	trimf	Linearna	Backpropagation	0,62394	0,57913	0,164067
32	trimf	Linearna	Hibridna	0,163076	0,163076	0,163076

Najmanja greška učenja primijećena je općenito kod svih scenarija kod kojih je primijenjena hibridna metoda učenja i kod kojih je izlazna funkcija bila linearnog oblika. Kod njih nije zamijećeno niti značajnije odstupanje u odnosu na broj epoha (koraka učenja). Tome idu u prilog i dosadašnja istraživanja koja su pokazala da prilikom rješavanja problema iz stvarnog svijeta, oblik funkcije pripadnosti ne utječe na točnost procesa, odnosno da su sustavi vanjskog svijeta relativno neosjetljivi na oblik funkcije pripadnosti [9], [65]–[68]. Stoga se u literaturi za kreiranje ekspertnog sustava ovog tipa najčešće koriste trokutasta ili trapezoidna funkcija pripadnosti, ali je moguće koristiti i bilo koju drugu funkciju pripadnosti, ukoliko bolje opisuje prirodu ulazne funkcije [9], [65]–[68].

4.1.4. Rezultati i komentar modela


Temeljem rezultata provedenih istraživanjem i primjenom navedenih metoda i postupaka, razvijen je model indeksa urbane mobilnosti koji, temeljem pokazatelja urbane mobilnosti (broj putovanja, trajanje putovanja, udaljenost) dobivenih analizom podskupa zapisa deriviranog iz zapisa za naplatu telekomunikacijskih usluga, modelira procjenu mobilnosti. Model je definirao pojedinačni odnos svakog ulaznog pokazatelja u odnosu na procjenu mobilnosti, te omogućava izražavanje procjene urbane mobilnosti jednim brojem uzimajući u obzir vrijednosti svih pokazatelja.

Razmotrimo odnos pokazatelja prijednog putovanja (udaljenosti) i procjene mobilnosti. Pokazatelj prijedne udaljenosti je normaliziran u odnosu na najduže putovanje u karakterističnom danu, tako da je sveden u interval $[0,1]$, kao i procjena mobilnosti, koja se također nalazi unutar intervala $[0,1]$. Na slici 56. prikazano je kretanje vrijednosti pokazatelja prijedne udaljenosti u odnosu na ukupnu procjenu urbane mobilnosti. Rezultat modela ukazuje da mobilnost raste zajedno s pokazateljem prijednog putovanja (udaljenosti), ali samo do određene granice, nakon čega slijedi stagnacija i pad, a potom opet lagani rast. Rezultat pokazuje da je inicijalna postavka, po kojoj mobilnost uopćeno raste s prijednom udaljenošću, djelomično potvrđena, te su definirani intervali za koje to pravilo vrijedi, kao i intervali u kojima broj putovanja negativno utječe na mobilnosti, odnosno uzrokuje njezinu stagnaciju ili pad. Dakle, možemo zaključiti da udaljenost u određenom intervalu povećava ukupnu mobilnost, ali postoji prijelomna točka u kojoj njezin doprinos više nije pozitivan, jer postoje intervali u kojima udaljenost narušava ukupnu ocjenu mobilnosti.




Slika 56. Odnos pokazatelja prijeđene udaljenosti i procjene mobilnosti (prikaz iz programskog alata Matlab)

Pokazatelj trajanja putovanja u određenom vremenskom intervalu je normaliziran u odnosu na putovanje koje je najduže trajalo u karakterističnom danu, tako da je sveden u interval $[0,1]$, kao i procjena mobilnosti, koja se također nalazi unutar intervala $[0,1]$. Na slici 57. prikazano je kretanje vrijednosti pokazatelja trajanja putovanja u odnosu na ukupnu procjenu urbane mobilnosti. Rezultat modela ukazuje da općenito mobilnost pada s povećanjem vrijednosti pokazatelja trajanja putovanja, uz po jedan segment na početku i na kraju funkcije, gdje procjena mobilnosti ima lagani rast u odnosu na trajanje putovanja. Rezultat pokazuje da je inicijalna postavka, po kojoj mobilnost generalno pada s rastom trajanja putovanja, uglavnom potvrđena te su definirani intervali za koje to pravilo vrijedi, kao i intervali u kojima trajanje putovanja pozitivno utječe na mobilnost, odnosno uzrokuje njezinu stagnaciju ili rast. Dakle, možemo zaključiti da povećanje trajanja putovanja uopćeno smanjuje ukupnu mobilnost, uz postojanje intervala u kojoj njezin doprinos nije negativan, odnosno u kojem trajanje putovanja povećava ukupnu procjenu mobilnosti.




Slika 57. Odnos pokazatelja trajanja putovanja i procjene mobilnosti (prikaz iz programskog alata Matlab)

Pokazatelj broja putovanja u određenom vremenskom intervalu je normaliziran u odnosu na najveći zabilježeni broj putovanja između istih izvora i odredišta u karakterističnom danu, tako da je sveden u interval $[0,1]$, kao i procjena mobilnosti, koja se također nalazi unutar intervala $[0,1]$. Na slici 58. prikazano je kretanje vrijednosti pokazatelja broja putovanja u odnosu na ukupnu procjenu urbane mobilnosti. Rezultat modela ukazuje da mobilnost raste zajedno s pokazateljem broja putovanja, uz jedan interval u središtu funkcije, gdje procjena mobilnosti ima lagani pad u odnosu na broj putovanja. Rezultat pokazuje da je inicijalna postavka, po kojoj mobilnost generalno raste s brojem putovanja, uglavnom potvrđena, te su definirani intervali za koje to pravilo vrijedi, kao i intervali u kojima broj putovanja negativno utječe na mobilnost, odnosno uzrokuje njezinu stagnaciju ili pad. Dakle, možemo zaključiti da broj putovanja u određenim intervalima poveća ukupnu mobilnost, te da postoji interval u kojoj njezin doprinos nije pozitivan, odnosno u kojem broj putovanja narušava ukupnu procjenu mobilnosti.




Slika 58. Odnos pokazatelja broja putovanja i procjene mobilnosti (prikaz iz programskog alata Matlab)


Na slikama koje slijede prikazani su zajednički učinci vrijednosti pojedinih pokazatelja na ukupnu mobilnost. Na slici 59. prikazan je odnos pokazatelja trajanja putovanja i broja putovanja u odnosu na ukupnu mobilnost, dok slika 60. prikazuje odnos istih pokazatelja iz druge perspektive. Na slici 61. prikazan je odnos pokazatelja udaljenosti i broja putovanja u odnosu na ukupnu mobilnost, dok slika 62. prikazuje odnos istih pokazatelja iz druge perspektive. Na slici 63. prikazan je odnos pokazatelja trajanja putovanja i udaljenosti u odnosu na ukupnu mobilnost, dok slika 64. prikazuje odnos istih pokazatelja iz druge perspektive.




Slika 59. Rezultat modela: odnos pokazatelja trajanja putovanja i broja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab)(1)




Slika 60. Rezultat modela: odnos pokazatelja trajanja putovanja i broja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab) (2)




Slika 61. Rezultat modela: odnos pokazatelja udaljenosti i broja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab)(1)



Slika 62. Rezultat modela: odnos pokazatelja udaljenosti i broja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab) (2)



Slika 63. Rezultat modela: odnos pokazatelja trajanja putovanja i udaljenosti u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab) (1)



Slika 64. Rezultat modela: odnos pokazatelja udaljenosti i trajanja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab) (2)

Pokazatelji urbane mobilnosti, koji se koriste kao ulaz za model procjene urbane mobilnosti, određeni su u prethodnim koracima postupka. Izračunavaju se za predefinirane vremenske intervale i to za svaki par baznih stanica (pripadajućih urbanih područja) između kojih je ostvareno putovanje, odnosno između kojih je mobilnost bila veća od nule. Ti pokazatelji potom ulaze u model, kao stvarne vrijednosti pokazatelja dobivenih prethodnim postupcima u procesu procjene urbane mobilnosti iz podskupa zapisa o naplati komunikacijskih usluga. Modeliranje se potom odvija za svaki par baznih stanica, što rezultira izračunom takozvanih parcijalnih indeksa urbane mobilnosti koji predstavljaju procjenu mobilnosti za taj par urbanih područja. Parcijalni indeksi urbane mobilnosti, kao izlazna vrijednost modela, tada se vraćaju u postupak procjene urbane mobilnosti. Potom se utvrđuje u kojoj mjeri svaki od njih sudjeluje u ukupnoj mobilnosti i izračunava se konačni indeks urbane mobilnosti (za odgovarajuće vremensko razdoblje), za odgovarajuću urbanu aglomeraciju. Postupak izračuna indeksa urbane mobilnosti iz parcijalnih indeksa urbane mobilnosti opisan je u poglavlju 3.

U sljedećim poglavljima slijedi implementacija postupka izračuna parcijalnih indeksa urbane mobilnosti u programskom okruženju. Izračun parcijalnih indeksa urbane mobilnosti bit će izveden kroz programski paket Simulink, dok će cijeli postupak izračuna pokazatelja i izračuna indeksa urbane mobilnosti biti definiran u programskom jeziku R. Dakle, korištenjem programskog jezika R izračunavaju se vrijednosti pokazatelja te se koriste kao ulazni podaci za Simulink, a izlazni rezultati (parcijalni indeksi urbane mobilnosti) iz Simulinka se vraćaju u programski jezik R, gdje se odvija proračun indeksa urbane mobilnosti.

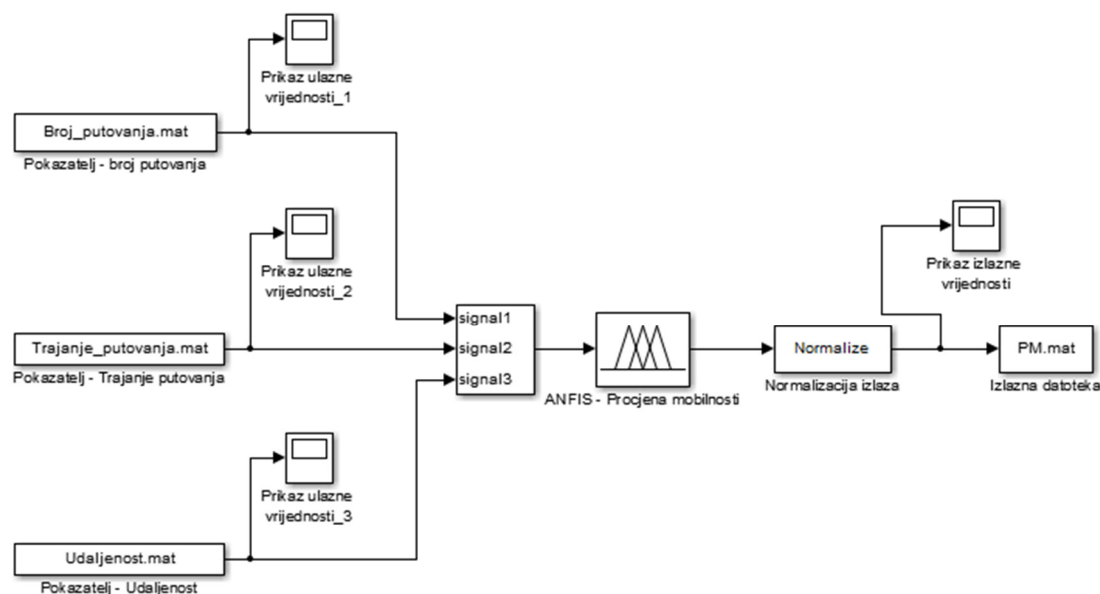
4.2. Implementacija modela u programskom okružju

Implementacija modela za izračun indeksa urbane mobilnosti izvršena je korištenjem alata Simulink. Simulink predstavlja grafički alat koji koristi matematičku jezgru programa Matlab u svrhu simulacije rada sustava. Simulink omogućuje modeliranje složenih sustava kao skupa međusobno povezanih podsustava. Simulacijska shema u Simulinku sastoji se od blokova i linija, tj. signala kojima se povezuju pojedini blokovi i teme te realiziraju jednadžbe koje opisuju sustav. Izgradnja simulacijskog modela obavlja se korištenjem dostupnih biblioteka gotovih grafičkih blokova [110]. Proces simulacija u Simulinku dijeli se na tri faze, i to na fazu prevođenja modela, fazu povezivanja modela i fazu simulacije. U prvoj fazi model

se prevodi u izvršni oblik, u drugoj se rezerviraju potrebni resursi i određuje poredak izvršavanja simulacije, a u trećoj fazi alat sukcesivno izračunava stanja i izlaze iz sustava [111].


Ulaz u model je definiran s tri ulazne varijable („Broj putovanja“, „Trajanje putovanja“, „Udaljenost“). Za potrebe simulacije kreiran je testni skup podataka, koji se sastoji od dvadeset vrijednosti ulaznih varijabli unutar intervala $[0,1]$. Potom se odvija permutacija kako bi se kreirali „scenariji“ u kojima su permutacije svake vrijednosti pojedinog pokazatelja sa svakom vrijednošću ostalih pokazatelja. Vrijednosti pokazatelja su generirani s rezolucijom 0,05. Moguće je definirati i veću rezoluciju. Primjerice, ukoliko se rezolucija definira na razini dvije decimale s korakom od 0,01, broj ulaznih veličina po svakom pokazatelju raste na 100, čime ukupan broj permutacija svih vrijednosti pokazatelja raste na jedan milijun, odnosno ulazni pokazatelji imaju po milijun vrijednosti po pokazatelju. Obrada tolike količine podataka zahtijeva značajne računalne i vremenske resurse, što za potrebe simulacije nije praktično. Stoga je definiran skup podataka koji ima manju rezoluciju s korakom 0,05, što znači da je za svaku ulaznu varijablu definirano 20 ulaznih vrijednosti (0,05, 0,1... 0,95, 1,00). Rezultat je 8.000 permutacija ulaznih pokazatelja, koji potom ulaze u sustav neizrazitog zaključivanja. Za svaki od 8.000 permutacija ulaznih vrijednost zatim se obavlja izračun procjene urbane mobilnosti, koji se potom normalizira i svodi na interval $[0,1]$. Rezultat je izlazni vektor s 8.000 polja koji daje procjenu mobilnosti, odnosno predstavlja parcijalni indeks urbane mobilnosti za svaku permutaciju ulaznih pokazatelja.

Korištenjem podataka iz stvarnog okružja, na temelju kojih se izračunavaju stvarne vrijednosti pokazatelja, sukladno koracima navedenim u prethodnim poglavljima, eliminira se potreba za permutacijama, jer se u model uvrštavaju stvarne vrijednosti pokazatelja. Stoga se za model koji se koristi za izračun parcijalnog indeksa urbane mobilnosti, ne koristi blok za permutaciju, već se za potrebe ove simulacije permutacija obavila u odvojenom procesu, temeljem kojeg je definiran konačan skup ulaznih vrijednosti. Blok shema modela za izračun indeksa urbane mobilnosti u programskom okružju Simulink prikazana je na slici 65.




Slika 65. Blok shema modela za izračun indeksa urbane mobilnosti u programskom okružju Simulink

S lijeve strane nalaze se ulazi u model, odnosno definiran je po jedan ulaz za svaki pokazatelj. On poziva datoteku koja sadrži ulazne vrijednosti pojedinih pokazatelja. Uz svaku ulaznu datoteku dodan je po jedan element koji služi za prikaz vrijednosti ulaznih veličina tijekom i nakon završetka simulacije (prikaz ulazne vrijednosti 1-3). Sustav neizrazitog zaključivanja u Simulinku može imati samo jedan ulaz, stoga je korištenjem odgovarajućeg koncentratora te podatke potrebno ujediniti u jedan ulazni signal. Pri tome je potrebno voditi računa da redoslijed ulaznih signala (signal 1, signal 2 i signal 3) odgovara redoslijedu pokazatelja u modelu. Izlazni signal iz koncentratora potom ulazi u model. Model se definira korištenjem parametara sustava neizrazitog zaključivanja koji je u prethodim koracima definiran kao optimalan i koji je izabran za procjenu indeksa urbane mobilnosti. Detaljni shematski prikaz strukture modela u Simulink programskom sučelju prikazan je na slici 66. Na slici su prikazane ulazne i izlazne vrijednosti pokazatelja koje su korištene za učenje modela, zatim su prikazana pravila kao rezultat tog učenja te potom proces defazifikacije, odnosno pretvaranja neizrazitih vrijednosti u numeričke varijable.



Slika 66. Detaljni prikaz modela u ANFIS-u

Model potom izračunava vrijednost procjene mobilnosti koja se potom u bloku za normalizaciju svodi na interval $[0,1]$. Rezultat se pohranjuje u izlaznu datoteku, tako da svaki redak predstavlja iznos parcijalnog indeksa urbane mobilnosti za svaki redak ulaznih pokazatelja. Grafički prikaz odnosa vrijednosti ulaznih pokazatelja i vrijednosti procjene mobilnosti kao rezultat simulacije, prikazan je na slici 67. Izlaz iz modela potom se koristi za izračun indeksa urbane mobilnosti cjelokupne urbane aglomeracije.




Slika 67. Grafički prikaz odnosa vrijednosti ulaznih pokazatelja i vrijednosti procjene mobilnosti

5. PRIMJENA POSTUPKA ODREĐIVANJA INDEKSA URBANE MOBILNOSTI

5.1. Implementacija postupka u programskom okruženju

Implementacija postupka procjene urbane mobilnosti izvršena je korištenjem nekoliko programskih okružja. Učitavanje skupa podataka, prilagodba ulaznih podataka te dekompozicija prostora izvršena je korištenjem programskog koda razvijenog u programskom okruženju R. Za vizualizaciju dekompozicije prostora korišten je programski alat otvorenog koda za geoprostornu analizu QGIS. Potom su u programskom jeziku R napisani moduli za izračun euklidske udaljenosti između baznih stanica, koji predstavljaju vrijednosti pokazatelja „udaljenosti“, te je kreiran modul za dijeljenje skupa podataka u podskupove, sukladno definiranim vremenskim okvirima. Slijedi ključni dio programskog koda, a to je primjena algoritma za identifikaciju migracija, odnosno za identifikaciju putovanja. Rezultat je pokazatelj broja putovanja. Potom podaci ulaze u modul za konsolidaciju i filtriranje podataka, te modul u kojem se podaci dijele na validacijski i kalibracijski skup. Podaci se potom iz forme tablica pretvaraju u formu matrica. Slijedi modul za normizaciju podataka. Normalizirani podaci tada se unose u programski jezik Matlab, gdje se poziva sustav neizrazitog zaključivanja, te se u njega unose podaci. Rezultat je parcijalni indeks urbane mobilnosti koji se pohranjuje u tablicu. Podaci se potom vraćaju u R, gdje se izlazni vektor parcijalnih indeksa urbane mobilnosti svodi na interval od [0,1] te se izračunava indeks urbane mobilnosti. Isti postupak provodi se i korištenjem skupa podataka za validaciju. Hodogram aktivnosti i pripadajući programski alati prikazani su na slici 68.



Slika 68. Hodogram aktivnosti i pripadajući programski alati

```
rm(list=ls())
LatLonfile <- LatitudeLongitude("F:/PhD/LatLonSH.csv")#LatLon of base stations in columns named by C12 i C13
bind <- paste(LatLonfile$C12,LatLonfile$C13,sep="_")
bind2 <- paste(LatLonfile$C13,LatLonfile$C12,sep="_")
freq <- as.data.frame(table(bind))
freq2 <- as.data.frame(table(bind2))
latlon <- unique(LatLonfile[,2:3])

x <- latlon$ODLat
y <- latlon$ODLon
xInterval = c(min(x),max(x))
yInterval = c(min(y),max(y))
try <- get_openstreetmap(bbox = c(min(y),min(x),max(y),max(x)))

dati<-data.frame(x,y)

vor_pts <- SpatialPointsDataFrame(cbind(dati$x,dati$y),dati, match.ID=TRUE)
vor <- SPointsDF_to_voronoi_SPolysDF(vor_pts)

vor_df <- fortify(vor)
load(file="E:/savedMap5_2.rda")

ggmap(mapImageData) +
  geom_point(data = dati, aes(x, y), shape=21,
            color = "white", fill = "steel blue") +
  geom_map(data = vor_df, map = vor_df, aes(x = long, y = lat, map_id = id),
          color = "#a5a5a5", fill = "FFFFFFF0", size = 0.25)
```

Slika 69. Primjer programskog koda unutar jezika R

Primjer dijela programskog koda (dekompozicija prostora) unutar programskog paketa R dān je na slici 69. Cjelokupan programski kod korišten za izradu ove disertacije, kao i pripadajući skup izvornih i obrađenih podataka, bit će dostupan u elektroničkom obliku kao dodatak disertaciji.

5.2. Primjena postupka nad simuliranim skupom podataka

U poglavlju 0 prikazan je postupak određivanja indeksa urbane mobilnosti. U tom poglavlju, u svrhu ilustracije procesa, korišteni su simulirani (slučajno generirani) podaci, temeljem kojih su formirane matrice koje sadrže vrijednosti pokazatelja. Međutim, u tom poglavlju još nije bio definiran model koji je uspostavljen u poglavlju 0, tako da ovo potpoglavlje predstavlja nastavak provođenja postupka koji je u poglavlju 0 završen zaključno sa šestim korakom postupka. Vrijednosti pokazatelja ulaze u model koji je definiran u poglavlju 0. Izlaz iz modela su parcijalni indeksi urbane mobilnosti, koji se potom koriste za izračun indeksa urbane mobilnosti aglomeracije. U model ulaze podaci iz matrice putovanja, iz matrice udaljenosti, iz matrice vremena, odnosno njihove normalizirane vrijednosti. Primjer vrijednosti pokazatelja tijekom odvijanja procesa normalizacije dān je na slikama u nastavku. Primjer simuliranih podataka koji su izlaz iz algoritma, kao tablice broja putovanja, tablice udaljenosti i tablice trajanja putovanja za tri vremenska intervala od O1 do O3, prikazan je na slici 11. u poglavlju 0. Iz tih podataka identificira se **matrica najbrojnijih putovanja**, pomoću koje se

potom računaju normalizirane matrice putovanja. Slijedi izračun matrice najdužih putovanja, potom izračun normalizirane matrice najdužih putovanja te izračun normalizirane matrice udaljenosti. Prikaz normaliziranih matrica putovanja, trajanja putovanja i udaljenosti dan je na slikama 70. i 71., a izračunat je za dva vremenska okvira i to za vremenski okvir O1 (00:00:00-02:59:59) i vremenski okvir O3 (06:00:00-08:59:59).

Norm. matrica putovanja							Norm. m. trajanje putovanja							Nor. dužina mreža				
	A	B	C	D	E		A	B	C	D	E		A	B	C	D	E	
A		0,112	0,113	0,063	0,072	A		0,192	0,384615385	0,385	0,385	A		0,068	0,114	0,068	0,273	
B	0,061		0,067	0,06	0,006	B	0,385		0,375	0,385	0,128	B	0,068		0,182	0,091	0,045	
C	0,113	0,025		0,069	0,025	C	0,071	0,385		0,071	0,385	C	0,114	0,182		0,045	0,091	
D	0,067	0,183	0,009		0,02	D	0,385	0,385	0,128205128		0,2	D	0,068	0,091	0,045		0,023	
E	0,112	0,113	0,063	0,072		E	0,192	0,385	0,384615385	0,385		E	0,273	0,045	0,091	0,023		


Slika 70. Normalizirane matrice putovanja, trajanja putovanja i nor. dužine mreže (udaljenosti) -simulirani podaci za vremenski okvir O1

Norm. matrica putovanja						Norm. m. trajanje putovanja						Nor. dužina mreža					
	A	B	C	D	E		A	B	C	D	E		A	B	C	D	E
A		1	0,245	0,925	0,485	A		1	1	1	1	A		0,068	0,114	0,068	0,273
B	0,67		0,6	1	1	B	1		0,975	1	1	B	0,068		0,182	0,091	0,045
C	1	1		1	0,497	C	1	1		1	1	C	0,114	0,182		0,045	0,091
D	1	0,684	0,885		1	D	1	1	1		0,52	D	0,068	0,091	0,045		0,023
E	1	0,245	0,925	0,485		E	1	1	1	1		E	0,273	0,045	0,091	0,023	


Slika 71. Normalizirane matrice putovanja, trajanja putovanja i nor. dužine mreže (udaljenosti) – simulirani podaci za vremenski okvir O3

Tako dobiveni podaci sada se koriste kao ulazne veličine za model urbane mobilnosti, što će rezultirati parcijalnim indeksom urbane mobilnosti. Ulaz u model mora biti u formatu [broj putovanja, trajanje putovanja, udaljenost], što znači da će kao ulaz u model za izračun (parcijalnog) indeksa urbane mobilnosti za okvir O1 i polja A_B biti [0,112; 0,192; 0,068], za polje A_C [0,113; 0,385; 0,114] i tako dalje. Podaci se transformiraju u oblik tablice te ulaze u model koji izračunava parcijalni indeks urbane mobilnosti, kao što je vidljivo na primjeru tablice u sklopu slike 72., pri čemu su u stupcima oznake parova baznih stanica (urbanih područja), u redcima NMP (vrijednosti iz normalizirane matrice broja putovanja), NTP (vrijednosti iz normalizirane matrice trajanja putovanja), NU (vrijednosti iz normalizirane matrice udaljenosti), normalizirane vrijednosti pokazatelja, a u retku pIM vrijednost parcijalnog indeksa urbane mobilnosti. Izlazne vrijednosti modela svode se na interval [0,1], te predstavljaju vrijednosti pIM koje se koriste u izračunu indeksa urbane mobilnosti


aglomeracije. Primjer vrijednosti pIM-a prije i poslije svođenja na interval prikazan je na slici 74.



Slika 72. Odnos pokazatelja i parcijalnog indeksa urbane mobilnosti za okvir O1



Slika 73. Odnos pokazatelja i parcijalnog indeksa urbane mobilnosti za okvir O3



Slika 74. Vrijednosti pIM-a prije i poslije svođenja na interval [0,1] za okvir O1

Po izračunu parcijalnog indeksa urbane mobilnosti u ukupnoj mobilnosti, slijedi izračun indeksa urbane mobilnosti cjelokupne urbane aglomeracije, koji se sukladno opisu u poglavlju 0, računa kao srednja vrijednost svih parcijalnih indeksa urbane mobilnosti dionica na kojima je ostvareno najmanje jedno putovanje. Tako primjerice, za okvir O1 (00:00:00 – 02:59:59) iz simuliranog skupa podataka indeks urbane mobilnosti iznosi **0,62; odnosno 62 %**. Za okvir O3 (06:00:00 – 08:59:59) iz simuliranog skupa podataka rezultat indeksa urbane mobilnosti **iznosi 0,5; odnosno 50 %**.

5.3. Primjena postupka nad stvarnim skupom podataka

Zapisi o aktivnostima u javnoj pokretnoj komunikacijskoj mreži (CDR) predstavljaju osnovni materijal za istraživanje. U istraživanju postupak procjene mobilnosti testiran je pomoću stvarnog javno dostupnog podskupa podataka izvedenog iz zapisa za naplatu telekomunikacijskih usluga iz javne pokretne komunikacijske mreže, a koji je dostupan na [87]. U dostupnom zapisu identifikacijski podaci korisnika zamijenjeni su privremenom identifikacijskom oznakom korisnika. Također, identifikacijska oznaka bazne stanice zamijenjena je novim nazivom koji sadrži informaciju o njezinom položaju u prostoru (geografska širina – geografska dužina.). Podaci se odnose na dio urbane aglomeracije grada Shenzena u Kini, a obuhvaćaju 480 baznih stanica koje pokrivaju površinu od otprilike 900 km² (30 x 30 km). Procjenjuje se da na području obuhvata živi otprilike 1,2 milijuna ljudi, dok u cijeloj urbanoj aglomeraciji, zajedno s prigradskim naseljima, živi otprilike 25 milijuna osoba [87]. Cjelokupna urbana aglomeracija (zajedno s prigradskim naseljima) prostire se na otprilike 20.000 m². Shenzhen je primjer eksplozivne brzine rasta i širenja gradova jer je još 1979. godine imao svega 30.000 stanovnika. Uslijed značajnog rasta broja stanovnika zbog snažnog ulaganja u industriju, kao i zbog obližnje granice s Hong Kongom, Shenzhen je u svjetskim razmjerima prepoznat kao najbrže rastući grad [112], [87]. Shenzhen je i najgušće naseljen grad u Kini s 17.000 stanovnika po km².

Skup podataka koji se koriste za analizu sastoji se od 38.218.717 zapisa o telekomunikacijskim aktivnostima za jedan karakterističan dan u trajanju od 24 sata. Sadrži podatke o telekomunikacijskim aktivnostima otprilike 450.000 korisnika, što predstavlja 37,5 % udjela populacije nastanjenje na tom području. Zapis sadrži u prosjeku 85 telekomunikacijskih aktivnosti po korisniku u karakterističnom danu.

Segment podskupa podataka iz zapisa za naplatu korišten za procjenu mobilnosti prikazan je na slici 75.

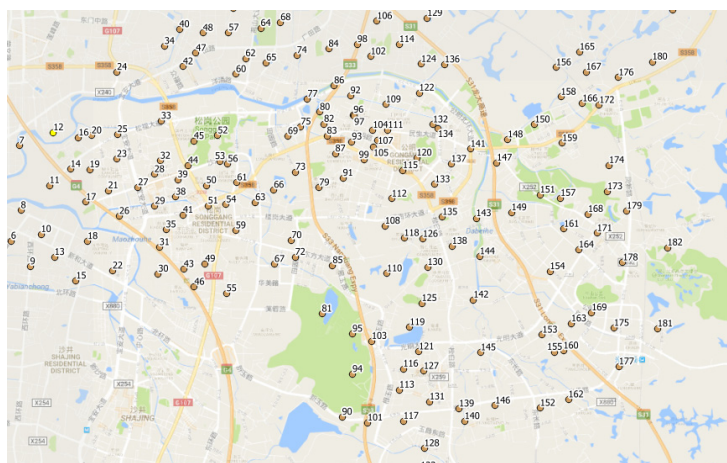
```
38218707 0055969823,21:29:29,114.0510417,22.5059028
38218708 0055969824,20:31:22,114.0561111,22.6257639
38218709 0055969824,20:32:31,114.0561111,22.6257639
38218710 0055969825,18:43:46,114.0450694,22.5251389
38218711 0055969825,18:43:20,114.0450694,22.5251389
38218712 0055969825,20:09:15,114.0427083,22.5245833
38218713 0055969825,20:09:51,114.0427083,22.5245833
38218714 0055969825,20:08:41,114.0427083,22.5245833
38218715 0055969825,18:44:44,114.0450694,22.5251389
38218716 0055969825,18:44:15,114.0450694,22.5251389
38218717 0055969826,21:57:41,114.0436806,22.5352083
```

Slika 75. Segment podskupa podataka iz zapisa za naplatu korišten za procjenu mobilnosti. Podaci iz [87].

	XCOORD	YCOORD	ID_ /
0	113.789931	22.765208	1
1	113.792569	22.761528	2
2	113.793333	22.755069	3
3	113.794931	22.776528	4
4	113.795000	22.769931	5
5	113.798264	22.759861	6
6	113.800278	22.781528	7
7	113.800694	22.766806	8

Slika 76. Segment tablice baznih stanica

Slijedi konverzija ulaznih podataka u tablicu te kreiranje tablice baznih stanica. Na obuhvaćenom području nalazi se 480 baznih stanica. Segment iz tablice baznih stanica, u kojima je vidljiva njihova oznaka i koordinate, nalazi se na slici 77. Bazne stanice su u funkciji mobilne mreže druge, treće i četvrte generacije mobilne telefonije.



Slika 77. Položaj baznih stanica i identifikacijska oznaka na dijelu obuhvaćenog područja

Potom je svakoj baznoj stanici pridijeljeno odgovarajuće područje pokrivanja primjenom Voronojevog postupka. Rezultat je dekompozicija prostora na Voronojeve ćelije. Sukladno broju baznih stanica, područje pokrivanja podijeljeno je na 480 urbanih područja. Prikaz Voronojevih ćelija s identifikacijskim oznakama baznih stanica, kojima pripadaju i vizualizacija njihova smještaja u prostoru na podlozi Google Maps, dan je na slici 78. Najmanja površina pokrivanja pripada ćeliji broj 356 i iznosi 0,045275 km², a najveća pripada ćeliji broj


100 i iznosi 198 km². Razlog velike površine ćelije broj 100 jest i to što se nalazi na rubnim dijelovima područja pokrivanja, gdje ne postoji granica prema drugim baznim stanicama. Primjer takvih ćelija su i broj 434 (88 km²), 242 (80 km²), 183 (66 km²) i 216 (53 km²). Ostale bazne stanice imaju znatno manje područje pokrivanja, a prosječna površina prostora koje pokriva jedna bazna stanica iznosi 2,69 km². Ukoliko se u prosječnu površinu ne uračuna površina pet najvećih rubnih ćelija, dolazimo do ukupne površine prostora od 804 km², a prosječno područje pokrivanja jedne ćelije iznosi 1,69 km². Slijedi proračun euklidskih udaljenosti između svih parova baznih stanica na području obuhvata. Ukupna udaljenost između svih baznih stanica izračunava se zbrojem udaljenosti između svakog pojedinog para baznih stanica. Ukupno je stoga izračunata udaljenost za 229.920 parova baznih stanica (svaka sa svakom, pri čemu izvor i odredište moraju biti različite bazne stanice), međutim, obzirom da je riječ o euklidskoj udaljenosti, udaljenost između dva para baznih stanica je jednaka bez obzira koja je od njih izvor, a koja je odredište putovanja, odnosno udaljenost ne ovisi o smjeru kretanja. Stoga je broj parova za izračun upola manji i iznosi 114.960 parova. Najkraća udaljenost između parova baznih stanica iznosi 0,007 km (udaljenost između bazne stanice 475 i 476), pri čemu je ukupno 12 parova baznih stanica na međusobnoj udaljenosti manjoj od 100 metara, a 1345 parova baznih stanica je na udaljenosti unutar jednog kilometra. Najduža udaljenost iznosi 42,9 km (udaljenost između baznih stanica 36 i 476) i prikazana je na slici 79. Ukoliko bi se zbrojila dužina između svih 114.960 parova baznih stanica, dobila bi se ukupna dužina od 1.897.808,59 km, pri čemu prosječna udaljenost između svih parova baznih stanica na mreži iznosi 1,81 km. Segment tablice udaljenosti između baznih stanica u kojoj je prikazana bazna stanica izvora, bazna stanica odredišta te njihova međusobna udaljenost u metrima i kilometrima prikazana je u tablici 41.

Tablica 41. Segment tablice udaljenosti između baznih stanica

Izvor	Odredište	Udaljenost (m)	Udaljenost (km)
1	2	489,9163303	0,48991633
1	3	1177,024366	1,177024366
1	4	1355,893962	1,355893962
1	5	738,6075398	0,73860754
1	6	1041,700449	1,041700449
1	7	2098,436747	2,098436747
1	8	1120,538407	1,120538407
1	9	1826,768887	1,826768887
1	10	1674,854961	1,674854961
1	11	2004,707202	2,004707202



Slika 78. Dekompozicija prostora na Voronojeve ćelije (lijevo) i preklapanje s kartografskom podlogom Google Maps (desno)



Slika 79. Udaljenost između dvije najudaljenije bazne stanice (36 i 476, označene žutom bojom) iznosi 42,9 km

U sljedećem koraku se cjelokupni zapis dijeli na podskupove sukladno vremenskim okvirima u karakterističnom danu, što rezultira podjelom na osam okvira kao što je prikazano u tablici 42.

Tablica 42. Vremenski okviri


O1 : 00:00:00 – 02:59:59,	O2 : 03:00:00 - 05:59:59,
O3 : 06:00:00 - 08:59:59,	O4 : 09:00:00 - 11:59:59,
O5 : 12:00:00 - 14:59:59,	O6 : 15:00:00 - 17:59:59,
O7 : 18:00:00 - 20:59:59,	O8 : 21:00:00 - 23:59:59.

Svi sljedeći koraci u postupku provode se zasebno za svaki vremenski okvir. Slijedi postupak identifikacija migracija. Migracijom se u ovom koraku smatra svaka promjena bazne stanice. Analizira se podskup podataka na način da se za svaku privremenu korisničku oznaku (za svakog korisnika) pregledava popis telekomunikacijskih aktivnosti. Kada se evidentira promjena bazne stanice, odnosno da je korisnik započeo novu telekomunikacijsku aktivnost na drugoj baznoj stanici, to se evidentira kao migracija te se pohranjuje na način da se evidentira identifikacijska oznaka bazne stanice koja je prethodila promjeni, a zatim identifikacijska oznaka bazne stanice na koju je korisnik prešao. Uz informaciju o paru baznih stanica pohranjuje se i posljednja vremenska oznaka na baznoj stanici koja je prethodila promjeni, kao i trenutak kada je korisnik prvi put zabilježen na drugoj baznoj stanici. Ukoliko je korisnik imao više telekomunikacijskih aktivnosti na jednoj baznoj stanici, uvijek se uzima samo posljednja vremena oznaka koja je zabilježena na baznoj stanici koja je prethodila migraciji. Dakle, u ovoj fazi evidentiraju se sve migracije, bez obzira na trajanje ili udaljenost, pa čak i one koje su posljedice balansiranja opterećenjem mobilnih mreža. Primjer identifikacije migracije iz ulaznog skupa podataka dan je na slici 80. Prikazane su dvije identificirane migracije i označene su krugom s oznakom jedan i dva. Crveni pravokutnik obuhvaća posljednji zapis na baznoj stanici prije promjene, a zeleni prvi zapis na novoj baznoj stanici. Crveni okvir predstavlja izvor, a zeleni odredište putovanja. Također, važno je primijetiti kako je korisnik na baznoj stanici 113.92125_22.7829167 prije promjene imao 11 telekomunikacijskih aktivnosti, u razdoblju od 17:33:34 pa do 19:20:30, te je stoga, radi pravilnog računanja vrijednosti pokazatelja, nužno koristiti uvijek posljednju aktivnost na baznoj stanici. Zapisi označeni svijetlozelenom bojom predstavljaju zapise među migracijama, te se ne mogu koristiti za izračun pokazatelja, pa se stoga odbacuju. Na analiziranom podatkovnom skupu identificirano je ukupno 2.133.369 migracija. Razdioba po vremenskim intervalima prikazana je na slici 81.,

u sklopu koje je i tablični prikaz. Osnovni podatkovni skup sadržavao je 38.218.717 zapisa, a identificirano je 2.133.369 migracija, za koje je korišteno dvostruko više zapisa (4.266.738), tako da je odbačeno 33.951.97 zapisa kao redundantnih, odnosno iz osnovnog skupa je iskorišteno 11 % skupa, dok je 89 % skupa redundantno.

	0055672110,17:33:34,113.9279167,22.7863194
	0055672110,17:37:48,113.9279167,22.7863194
	0055672110,17:43:21,113.9279167,22.7863194
	0055672110,17:44:56,113.9279167,22.7863194
	0055672110,17:47:04,113.9279167,22.7863194
	0055672110,17:47:15,113.9279167,22.7863194
	0055672110,17:47:47,113.9279167,22.7863194
	0055672110,17:49:23,113.9279167,22.7863194
	0055672110,17:59:30,113.9279167,22.7863194
	0055672110,18:02:13,113.9279167,22.7863194
	0055672110,18:12:27,113.9279167,22.7863194
1	0055672110,19:20:30,113.9279167,22.7863194
	0055672110,19:31:52,113.92125,22.7829167
	0055672110,19:36:35,113.92125,22.7829167
	0055672110,19:43:20,113.92125,22.7829167
2	0055672110,19:46:44,113.92125,22.7829167
	0055672110,19:46:55,113.9279167,22.7863194
	0055672110,19:49:04,113.9279167,22.7863194


Slika 80. Identifikacija dvije migracije korisnika identifikacijske oznake „005672110“ (ilustracija)



Slika 81. Ukupan broj migracija prije filtriranja po vremenskim okvirima (broj migracija)


Slijede koraci u kojima se svakoj migraciji na temelju informacija iz tablice udaljenosti pridjeljuju udaljenosti, izračunava vrijeme trajanja putovanja i identificira brzina putovanja. Ove vrijednosti koristit će se u kasnijoj fazi postupka za definiranje pokazatelja. U ovoj fazi postupka, slijedi njihovo filtriranje. Kako je već navedeno u prethodnom poglavlju 0, filtriranje podataka se odnosi na udaljenost (filtriraju se sva putovanja koja su kraća od jednog kilometra), zatim na vrijeme (filtriraju se sva putovanja kraća od 10, a duža od 60 minuta) te brzinu (filtriraju se sve prosječne brzine putovanja veće od 100 km/h). Primjenom filtra uklonjene su

sve migracije koje ne zadovoljavaju uvjete, a ostavljene su one migracije koje su bile duže od 1 km, koje su trajale između 10 i 60 minuta i u kojima je prosječna brzina kretanja bila manja od 100 km/h. Kao rezultat filtriranja uklonjeno je gotovo 95 % identificiranih migracija, odnosno od 91 % do 97 % po pojedinom vremenskom okviru. Ukupan broj migracija za promatrano područje za karakterističan dan iznosi 110.902 migracija. Njihova razdioba po vremenskim okvirima prikazana je na slici 82.



Slika 82. Broj migracija poslije filtriranja po vremenskim okvirima (broj migracija)


U sklopu ovog postupka odvojiti će se skup podataka za validaciju modela. Kao što je navedeno u opisu postupka, za izračun indeksa urbane mobilnosti koristit će se 80 % dostupnih podataka, dok će se 20 % koristiti za validaciju. Obzirom da matrica sadrži ukupno 480 x 480 polja, za učenje modela koristit će se podaci u 46.080 polja iz daljnjeg desnog dijela matrice, odnosno koristit će se podaci koji kreću s retkom 266 i stupcem 266 te se protežu do kraja matrice. Naravno, izbor podataka nije apsolutno vezan za položaj u matrici, već se, ukoliko podataka u tom dijelu matrice nema dovoljno, uzima posljednjih 20 % podataka iz cijelog skupa. Ilustracija matrice i odnos količine podataka za procjenu urbane mobilnosti i one za validaciju dani su na slici 83.




Slika 83. Ilustracija količine podataka korištene za procjenu mobilnosti (zeleno polje) i skupa podataka za validaciju (crveno polje)

Slijedi izračun preostalih pokazatelja. Pokazatelj broj putovanja izračunat je u prethodnom koraku, kao broj ukupnih migracija po pojedinom vremenskom okviru nakon filtriranja. Pokazatelj euklidske udaljenosti izračunat je također u prethodnim koracima, kao udaljenost između svakog para baznih stanica. Važno je naglasiti kako će se prilikom procjene mobilnosti uzimati u obzir samo one udaljenosti između onih parova baznih stanica između kojih je putovanje i ostvareno. Slijedi izračun jedinog preostalog pokazatelja, odnosno pokazatelja srednjeg vremena putovanja. Pokazatelj srednjeg vremena putovanja računa se kao srednja vrijednost trajanja svih putovanja između pojedinih parova baznih stanica u pojedinom vremenskom okviru. Za svaki par baznih stanica u odgovarajućem vremenskom okviru identificiraju se sva putovanja koja su ostvarena. Potom se uzimaju sve vrijednosti razlike u vremenu između vremenske oznake na ćeliji koja je odredište putovanja, kao i na ćeliji koja je izvor putovanja. Potom se za sve parove baznih stanica izračunava srednja vrijednost tih vremena, koja se potom pohranjuje u matricu srednjih vremena putovanja za svaki pojedini vremenski okvir.

Ukupna suma svih srednjih vrijednosti trajanja putovanja u svim vremenskim intervalima dana je na slici 84., odnosno slika 85. prikazuje najveće vrijednosti trajanja putovanja po pojedinim parovima baznih stanica u svim vremenskim okvirima.



Slika 84. Suma svih srednjih vrijednosti trajanja putovanja po vremenskim okvirima (u satima)



Slika 85. Najduža trajanja pojedinih putovanja po vremenskom okviru

Slijedi postupak normalizacije podataka. Kao što je opisano u poglavlju 3, normalizacija broja putovanja računa se na način da se identificira najveća vrijednost pokazatelja broja putovanja za pojedini par izvora i odredišta unutar svih osam vremenskih razdoblja, koja se potom pohranjuje u novu matricu, a koja nosi naziv matrica najbrojnijih putovanja. Nakon toga slijedi izračun normalizirane vrijednosti količine putovanja. On se računa na način da se vrijednosti pokazatelja u osam matrica za svako pojedino razdoblje podijele s vrijednošću matrice najbrojnijih putovanja, te se tako dobivaju normalizirane matrice putovanja za sve vremenske okvire. Kao što je opisano u poglavlju 3, normalizacija pokazatelja trajanja putovanja računa se na način da se identificira najveća vrijednost pokazatelja trajanja putovanja za pojedini par izvora i odredišta unutar svih osam vremenskih razdoblja, koja se potom pohranjuje u novu matricu, a koja nosi naziv matrica najvećih trajanja putovanja. Nakon toga slijedi izračun normalizirane vrijednosti trajanja putovanja koji se računa na način da se vrijednosti pokazatelja u osam matrica za svako pojedino razdoblje podijele s vrijednošću matrice najvećih količina putovanja, te se tako dobivaju normalizirane matrice putovanja za svako vremensko razdoblje. Kao što je objašnjeno u poglavlju 3, vrijednost pokazatelja udaljenosti se, za razliku od prethodno opisana dva pokazatelja, ne mijenja u vremenu, jer je riječ o fizikalnoj veličini koja je konstantna i predstavlja euklidsku udaljenost između parova baznih stanica. Stoga se normalizacija računa na način da se dužina pojedine dionice između parova izvora i odredišta normalizira s dužinom ukupne mreže, odnosno s ukupnom dužinom svih dionica na kojima je ostvareno putovanje u svim vremenskim okvirima. Normalizirane vrijednosti se potom pohranjuju u tablicu normaliziranih vrijednosti udaljenosti te se potom koriste za daljnje izračunavanje indeksa urbane mobilnosti. Detalj iz tablice svih udaljenosti između svih parova baznih stanica (prvih 10 od ukupno 480 redaka i stupaca) prikazan je na


slici 86. Detalj iz tablice udaljenosti između svih parova baznih stanica u kojima je ostvareno putovanje u karakterističnom danu (prvih 30 od ukupno 480 redaka i stupaca) prikazan je na slici 87. Najduža dionica mreže na kojoj je ostvareno putovanje po vremenskom okviru prikazana je na slici 88. Ukupna duljina mreže na kojoj je ostvareno putovanje po vremenskim okvirima, a koja se koristi za normalizaciju svakog pojedinog okvira, prikazana je na slici 89. Detalj iz normalizirane tablice udaljenosti za vremenski okvir O1 prikazan je na slici 90.

	1	2	3	4	5	6	7	8	9	10
1		0,48991633	1,177024366	1,355893962	0,73860754	1,041700449	2,098436747	1,120538407	1,826768887	1,674854961
2	0,48991633		0,720174341	1,680294769	0,964336759	0,613847758	2,354236999	1,01972131	1,355662754	1,349309666
3	1,177024366	0,720174341		2,384212004	1,656171809	0,734180829	3,018395683	1,504968723	0,999031831	1,451003693
4	1,355893962	1,680294769	2,384212004		0,731299989	1,87891931	0,780535231	1,229775102	2,627872491	2,009995179
5	0,73860754	0,964336759	1,656171809	0,731299989		0	1,165486317	1,395267655	0,68015582	1,944528961
6	1,041700449	0,613847758	0,734180829	1,87891931	1,165486317		0	0,809290163	0,808537911	0,782389664
7	2,098436747	2,354236999	3,018395683	0,780535231	1,395267655	2,410536579		0	1,63243343	3,060899287
8	1,120538407	1,01972131	1,504968723	1,229775102	0,68015582	0,809290163	1,63243343		0	1,435801251
9	1,826768887	1,355662754	0,999031831	2,627872491	1,944528961	0,808537911	3,060899287	1,435801251		0
10	1,674854961	1,349309666	1,451003693	2,009995179	1,450842858	0,782389664	2,300663911	0,790356273	0,862124689	

Slika 86. Detalj iz tablice svih udaljenosti između svih parova baznih stanica (prvih 10 od ukupno 480 redaka i stupaca)

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
1							2,1			1,67	2														
2								1,36	1,35	1,98															
3									1,45	2,44	3,63	1,62				3,84									
4								2,63	2,01	1,39		2,68	1,86					2,34							
5												2,1	1,97					2,43	2,84						
6												1,18	2,36		3,12		1,95			2,78					
7	2,1											2,95		3,71					1,86		3,95			2,51	
8															2,35			2,03	2,61			2,76			
9	1,83														3,47	2,16		2,88	3,65				5,38	4	
10	1,67	1,35	1,45	2,01		0,78		0,79						1,48	2,61	1,4		2,8	2,03				4,52	3,18	
11	2	1,98	2,44	1,39										1,41	1,02	1,71	1,1	1,65	1,5				3,33	2,15	
12			3,63	1,67	2,15	2,94										0,66		2,88	1,31		2,02		2,22	1,63	
13				2,68	2,1												1,6	2,38	3,21			2,94	4,93	3,48	
14					1,97	2,36												1,87		1	1,1	2,78	1,2	1,48	
15					2,91		3,71		1,23										3,68	2,42	0,96	3,24	5,37	3,84	
16						1,53	2,35		2,61		0,66											3,46		1,92	0,99
17					2,25			1,67	2,16		1,02	1,94											3,37	1,89	
18							1,87	1,6		1,71	2,88											0,98	4,33	2,8	
19								2,03	2,88		1,31	2,38	0,49										2,55	1,13	
20				2,84	3,35			3,65	2,8	1,65	3,21	1		0,33									1,73		
21			3,48			2,53	2,76	2,03		2,02	2,16	1,1	2,42	1,53											
22						3,95	2,79	2,1		3,8	1,52	2,78	0,96												
23							2,76	3,49	2,7				1,2	3,24	1,11										
24									4,52	3,33				5,37	3,37	4,33				2,99					
25	4,13									3,18	2,15	1,63		1,48	3,84	0,99	1,89	2,8							

Slika 87. Detalj iz tablice udaljenosti između svih parova baznih stanica u kojima je ostvareno putovanje u karakterističnom danu (prvih 25 od ukupno 480 redaka i stupaca)



Slika 88. Najduža dionica mreže na kojoj je ostvareno putovanje po vremenskom okviru



Slika 89. Ukupna duljina mreže na kojoj je ostvareno putovanje po vremenskim okvirima

	1	2	3	4	5	6	7	8	9	10
1										0,0000587
2										
3										
4										
5										
6										
7										
8										
9										
10		0,0000473	0,0000509							
11										
12										
13			0,0000940							
14										
15										
16										
17				0,0000787						
18										
19										
20				0,0000995						
21										
22										
23										
24										
25	0,0001449								0,0001115	
26										
27										
28										
29								0,0001235		
30										
31									0,0001063	
32										
33			0,0001516							
34		0,0002286								
35										
36										
37										
38	0,0001705									

Slika 90. Detalj iz tablice normaliziranih udaljenosti za vremenski okvir O1

Broj parova baznih stanica po vremenskom okviru nakon filtriranja, s brojem parova baznih stanica koji će se koristiti za procjenu urbane mobilnosti, kao i s brojem parova koji će se koristiti za validaciju, prikazani su u tablici 43.

Do sada su izračunate stvarne i normalizirane vrijednosti pokazatelja za svaki vremenski okvir. Normalizirani podaci koriste se kao ulaz u model za izračun indeksa urbane mobilnosti. Prvi korak jest izračun parcijalnog indeksa urbane mobilnosti. Podaci se priređuju tako da se za svaki vremenski okvir formira tablica koja sadrži par baznih stanica na koji se pokazatelji odnose, te njihove normalizirane veličine. U tablici 43 prikazan je segment tablice za vremenski okvir O1 sa pokazateljima i izračunatim vrijednostima parcijalnog indeksa urbane mobilnosti.

Tablica 43. Broj parova baznih stanica nakon filtriranja

Vremenski okvir	Ukupan broj parova baznih stanica	Broj parova koji će se koristiti za procjenu urbane mobilnosti	Broj parova koji će se koristiti za validaciju
O1	2639	2112	527
O2	2629	2112	517
O3	2611	2112	499
O4	2673	2139	534
O5	2641	2112	529
O6	2620	2096	524
O7	2619	2096	523
O8	2024	1620	404


Podaci se učitavaju u ranije priređeno okruženje u sklopu programskog alata Matlab, gdje se pomoću ekspertnog sustava određuje indeks urbane mobilnosti za svaki par baznih stanica unutar svakog pojedinog okvira. Rezultat je parcijalni indeks urbane mobilnosti za svaki par baznih stanica (urbanih područja). Segment tablice za vremenski okvir O1 s pokazateljima i izračunatim vrijednostima parcijalnog indeksa urbane mobilnosti dan je u tablici 44. Vrijednosti parcijalnog indeksa urbane mobilnosti za svaki vremenski okvir prikazane su na slikama 91., 92., 93., 94., 95., 96., 97. i 98. Za svaki vremenski okvir identificirano je deset parova baznih stanica kod kojih su vrijednosti parcijalnog indeksa urbane mobilnosti najveće. Popis ćelija s najvećim vrijednostima parcijalnog indeksa urbane mobilnosti za svaki vremenski okvir dan je u tablici 45.

Tablica 44. Segment tablice za vremenski okvir O1 sa pokazateljima i izračunatim vrijednostima parcijalnog indeksa urbane mobilnosti


Izvor	Odredište	nBP	nTP	nUD	npim(O1)
1	87	0,0307692	0,5013774	0,0001122	0,5692346
1	68	0,0392157	1,0000000	0,0000528	0,5692343
2	22	0,0416667	0,7070707	0,0000467	0,2976017
2	147	0,0476190	0,5568182	0,0001111	0,8949618
2	134	0,0571429	0,8352273	0,0001034	0,2178587
2	13	0,0666667	0,3535354	0,0001601	0,5692373
2	89	0,0714286	0,3888889	0,0002764	0,5692345
2	89	0,0740741	0,6086957	0,0001592	0,5692346
3	111	0,0800000	0,5785124	0,0000446	0,5692343
3	53	0,0800000	1,0000000	0,0000533	0,1066740

Tablica 45. Deset parova baznih stanica sa najvećim iIM za vremenske okvire O1-O8


Okvir O1	Izvor	149	150	101	32	135	110	151	90	121	56
	Odredište	171	126	103	171	94	109	171	63	117	115
	pim(O1)	0,99	0,98	0,98	0,96	0,95	0,94	0,93	0,93	0,93	0,93
Okvir O2	Izvor	93	23	113	89	61	94	114	68	136	100
	Odredište	116	33	218	77	89	153	149	82	112	83
	pim(O2)	0,99	0,99	0,98	0,97	0,95	0,94	0,91	0,91	0,91	0,91
Okvir O3	Izvor	129	116	8	48	19	41	33	3	26	306
	Odredište	110	238	23	37	14	112	81	364	31	113
	pim(O3)	0,98	0,73	0,72	0,72	0,72	0,72	0,72	0,72	0,72	0,72
Okvir O4	Izvor	113	68	129	163	142	125	340	25	38	337
	Odredište	140	108	154	50	146	112	250	420	2	90
	pim(O4)	0,96	0,94	0,93	0,89	0,83	0,82	0,73	0,70	0,70	0,70
Okvir O5	Izvor	68	12	40	19	36	46	329	68	42	19
	Odredište	137	378	27	347	8	1	350	397	3	346
	pim(O5)	0,91	0,71	0,71	0,71	0,71	0,71	0,71	0,71	0,71	0,71
Okvir O6	Izvor	21	68	148	5	8	24	15	77	7	34
	Odredište	34	76	162	14	99	342	5	68	432	386
	pim(O6)	0,90	0,89	0,89	0,81	0,81	0,81	0,81	0,81	0,81	0,81
Okvir O7	Izvor	106	259	34	115	18	22	107	180	28	115
	Odredište	134	360	31	141	27	121	129	35	36	355
	pim(O7)	0,98	0,95	0,94	0,91	0,91	0,91	0,91	0,91	0,90	0,88
Okvir O8	Izvor	107	137	154	319	65	169	95	90	37	135
	Odredište	161	111	191	366	96	146	79	140	116	174
	pim(O8)	1,00	0,99	0,97	0,96	0,95	0,94	0,92	0,92	0,92	0,91




Slika 91. Vrijednosti PIM-a za okvir O1




Slika 92. Vrijednosti PIM-a za okvir O2




Slika 93. Vrijednosti PIM-a za okvir O3




Slika 94. Vrijednosti PIM-a za okvir O4




Slika 95. Vrijednosti PIM-a za okvir O5



Slika 96. Vrijednosti PIM-a za okvir O6



Slika 97. Vrijednosti PIM-a za okvir O7




Slika 98. Vrijednosti PIM-a za okvir O8

Temeljem izračunatih vrijednosti parcijalnih indeksa urbane mobilnosti, slijedi izračun **indeksa urbane mobilnosti** za svaki vremenski okvir. Indeks urbane mobilnosti računa se kao srednja vrijednosti parcijalnih indeksa urbane mobilnosti između svakog para baznih stanica (urbanih područja) između kojih je ostvareno putovanje u odgovarajućem vremenskom okviru (O). Vrijednosti indeksa urbane mobilnosti po vremenskim okvirima za osnovni skup podataka, te za skup podataka koji je korišten za validaciju, prikazani su u tablici 46. Odstupanje vrijednosti indeksa urbane mobilnosti iz osnovnog skupa u odnosu na podatke korištene za validaciju prikazan je na slici 99., a usporedba vrijednosti indeksa urbane mobilnosti iz osnovnog skupa i s podacima za validaciju dana je na slici 100.


Validacija modela, korištenjem skupa podataka koji se sastoji od 20 % ukupnog skupa podataka, pokazuje da su moguća odstupanja u razmaku od 3 % do 11 % u odnosu na vrijednost koja je dobivena korištenjem osnovnog skupa podataka. Odstupanje kod sedam vremenskih okvira ne prelazi vrijednost od 7 %, te samo u jednom okviru ima vrijednost veću od 11 %. Prosječno odstupanje za sve vremenske okvire iznosi 6 %, odnosno pokazuje da pouzdanost modela iznosi 94 %.

Tablica 46. Vrijednosti indeksa urbane mobilnosti po vremenskim okvirima za osnovni skup podataka, te za skup podataka koji je korišten za validaciju

	O1	O2	O3	O4	O5	O6	O7	O8
IM	51,14%	54,50%	69,02%	64,03%	66,65%	76,57%	56,14%	52,65%
IM (validacija)	54,57%	57,83%	70,92%	68,20%	70,13%	69,14%	58,71%	56,59%
Razlika	6%	6%	3%	6%	5%	-11%	4%	7%



Slika 99. Odstupanje vrijednosti indeksa urbane mobilnosti iz osnovnog skupa u odnosu na podatke korištene za validaciju




Slika 100. Usporedba vrijednosti indeksa urbane mobilnosti iz osnovnog skupa i s podacima za validaciju (1)

Kao što je definirano u poglavlju 0, slijedi izračun dodatnog pokazatelja, koeficijenta **udjela u ukupnoj mobilnosti** ($\alpha_{i,j}$). Za svaki par baznih stanica izračunava se vrijednost koja predstavlja umnožak broja putovanja između tih parova i njihove udaljenosti. Zbroj svih tih umnožaka unutar jednog okvira predstavlja ukupnu mobilnost u tom vremenskom okviru, a prikazan je u tablici 47. Vrijednost količine mobilnosti između pojedinog para baznih stanica potom se dijeli s ukupnom mobilnosti u tom vremenskom okviru. Rezultat je udio s kojim pojedini par baznih stanica sudjeluje u ukupnoj mobilnosti unutar jednog vremenskog okvira.

Tablica 47. Ukupna količina mobilnosti za svaki vremenski okvir

Vremenski okvir	O1	O2	O3	O4	O5	O6	O7	O8
Količina mobilnosti	76.365	114.043	223.260	152.107	192.886	151.974	347.662	301.795

Također, za svaki okvir tada je izvršena analiza koja pokazuje koji su minimalni i maksimalni koeficijenti $\alpha_{i,j}$ za svaki vremenski okvir. Najmanje i najveće vrijednosti koeficijenta po svakom vremenskom okviru prikazane su u tablici 48. U svrhu identifikacije područja na kojima se odvija najveća mobilnost, kreirana je i zbirna tablica koja sadrži sumu svih ukupnih mobilnosti za sve parove baznih stanica i za sve vremenske okvire. Time je dobiven pregled nad ukupnom mobilnošću urbane aglomeracije unutar razdoblja od 24 sata. Tablica je vizualizirana na način da je definiran raspon boja od crvene do zelene, s pripadajućim nijansama, pri čemu najintenzivnija nijansa crvene boje predstavlja par baznih stanica (urbanih



Tablica 48. Tablica sa najmanjim i najvećim vrijednostima koeficijenta $\alpha_{i,j}$

	min α (i,j)	max α (i,j)
O1	0,0012%	0,5135%
O2	0,0008%	0,4203%
O3	0,0011%	0,5548%
O4	0,0012%	0,3989%
O5	0,0008%	0,4191%
O6	0,0009%	0,4191%
O7	0,0009%	0,1879%
O8	0,0002%	0,1587%

Svi pokazatelji, parcijalni indeksi urbane mobilnosti i indeks urbane mobilnosti računaju se za svaki vremenski okvir, čime je omogućen uvid u stanje i promjenu stanja urbane mobilnosti po vremenu. Postupak je validiran korištenjem skupa podataka za validaciju, koji je izveden iz osnovnog skupa. Ovime je dokazana hipoteza ovoga znanstveno-istraživačkog rada koja kaže da se urbana mobilnost stanovnika u gradskom okruženju u određenom vremenskom razdoblju može opisati indeksom urbane mobilnosti, zasnovanim na informacijama o zabilježenim telekomunikacijskim aktivnostima korisnika u javnoj pokretnoj komunikacijskoj mreži.

6. ZAKLJUČNO RAZMATRANJE

Svrha ovog znanstveno-istraživačkog rada bila je dokazati mogućnost primjene podataka o telekomunikacijskim aktivnostima korisnika za potrebe procjene urbane mobilnosti, zatim identificirati pokazatelje urbane mobilnosti, definirati postupak njihova izračuna, te potom definirati model koji će iz vrijednosti tih pokazatelja dati procjenu urbane mobilnosti. Definirani cilj istraživanja bio je uspostaviti postupak procjene urbane mobilnosti stanovništva kao kvantitativne veličine procesa urbanih migracija izazvanih društveno-ekonomskim aktivnostima. Cilj je uspostavljanje modela za procjenu urbane mobilnosti koji je zasnovan na zapisima o aktivnostima korisnika u javnim pokretnim komunikacijskim mrežama, a koji je u funkciji određivanja novog indeksa za procjenu urbane mobilnosti. S obzirom na problem istraživanja, postavljenu hipotezu, te svrhu i cilj znanstvenog istraživanja, bilo je potrebno provesti istraživanje koje će obuhvatiti brojne parametre s ciljem određivanja modela za procjenu urbane mobilnosti. U istraživanju je definiran postupak procjene urbane mobilnosti zasnovan na korištenju odgovarajućeg ekspertnog sustava za procjenu urbane mobilnosti.

Kao osnovni materijal za istraživanje korišten je strukturirani zapis o mrežnim aktivnostima korisnika u javnoj pokretnoj komunikacijskoj mreži koji se koristi u svrhu naplate telekomunikacijskih usluga. Navedeni zapisi sadrže informaciju o vremenu početka aktivnosti i dužinu trajanja usluge, kao i vrstu aktivnosti, a operatori ih koriste u svrhu evidencije telekomunikacijskih aktivnosti korisnika, na temelju kojih se formira račun za pružene usluge. Razvijen je algoritam koji temeljem ovih informacija identificira kretanje korisnika unutar urbane aglomeracije koja je obuhvaćena istraživanjem, odnosno identificiraju se putovanja. Pri tome se putovanjima korisnika smatra kretanje korisnika između područja pokrivanja dvije bazne stranice javne pokretne komunikacijske mreže na kojima je ostvario telekomunikacijsku aktivnost i na kojima je boravio dovoljno dugo da se te lokacije mogu identificirati kao izvor i odredište putovanja, a ne samo tranzitne lokacije.

Temeljem informacije o identificiranim putovanjima definiran je prvi pokazatelj „broj putovanja“, koji se odnosi na broj kretanja između pojedinih urbanih područja u odgovarajućem vremenskom okviru. Navedeni pokazatelj predstavlja broj svih zabilježenih kretanja svih korisnika između pojedinih urbanih područja u odgovarajućem vremenskom okviru, a prikazuje se matricom putovanja. Kako bi pokazatelj broja putovanja bio primjenjiv u svim urbanim okružjima, bez obzira na njihovu veličinu, površinu ili broj stanovnika, potrebno ga je

normalizirati. Vrijednost pokazatelja broja putovanja normalizirana je tako da je izračunat udio putovanja između pojedinih izvora i odredišta u odnosu na najveći zabilježeni broj putovanja između tih izvora i odredišta u karakterističnom danu.

Na osnovi informacije o razlici u vremenu između dvije telekomunikacijske aktivnosti korisnika na različitim baznim stanicama, definiran je drugi pokazatelj: trajanje putovanja. Pokazatelj trajanja putovanja odnosi se na trajanje svakog pojedinog putovanja u promatranom vremenskom okviru. Vrijednost pokazatelja trajanja putovanja je normalizirana tako da se izračuna udio pojedinog putovanja u odnosu na najduže registrirano putovanje, pri čemu se vrijednost trajanja pojedinog putovanja normalizira u odnosu na putovanje koje je najduže trajalo u karakterističnom danu. Pri tome se putovanjem koje je najduže trajalo smatra ono putovanje koje je u vremenskom smislu trajalo najduže, a da su pritom i izvor i odredište ostali unutar iste urbane aglomeracije, odnosno područja pokrivanja.

Treći i posljednji identificirani pokazatelj urbane mobilnosti jest pokazatelj (euklidske) udaljenosti. Pokazatelj udaljenosti koristi se kao aproksimacija prijednog puta. Odnosi se na udaljenost koju je korisnik prevalio na putovanju između pojedinih urbanih područja, odnosno udaljenost između izvora i odredišta putovanja. Prijedena udaljenost aproksimira se udaljenošću između parova baznih stanica koje su detektirane kao izvor i odredište putovanja. Za izračun svakog pojedinog pokazatelja definiran je odgovarajući postupak, koji uključuje primjenu razvijenih algoritama.

Nakon što su definirani pokazatelji urbane mobilnosti te utvrđen i verificiran postupak njihova izračuna, slijedi postupak u kojem se utvrđuje odnos vrijednosti pokazatelja urbane mobilnosti i vrijednosti procjene mobilnosti. Za definiranje tog odnosa korištena je metoda „crpljenja znanja“ eksperata, a provedena anketiranjem. Eksperti su temeljem vlastite prosudbe (znanja) svakom pitanju pridijelili odgovarajuću vrijednost korištenjem predloženog postupka za procjenu mobilnosti. Anketiranje stručnjaka provedeno je na radionicama i putem telekonferencije. Izabrani su stručnjaci iz Republike Hrvatske i inozemstva koji se bave mobilnošću i to: stručnjaci za mobilnost iz akademske zajednice, stručnjaci koji se bave mobilnošću iz privatnog sektora te stručnjaci iz javnog sektora koji se bave mobilnošću na razini pojedinih gradova. Preliminarna analiza podataka napravljena je u svrhu provjere konzistentnosti odgovora te identifikacije pojedinih pitanja gdje postoji izrazito slaganje ili razlika u mišljenju eksperata. Razlike u mišljenju eksperata očekivane su jer eksperti mobilnost sagledavaju iz različitih područja, u ovisnosti o svom području proučavanja.

Za formiranje modela ekspertnog sustava izabrana je tehnologija neizrazite logike. Korištena je ANFIS metoda, koja predstavlja tehniku strojnog učenja koja koristi neizrazitu logiku kao model zaključivanja i neuronsku mrežu kao model „pohrane“ znanja. Rezultat je sustav koji omogućava korištenje dobro poznatih algoritama za učenje umjetnih neuronskih mreža, koji se ne mogu koristiti u sustavima za neizrazito zaključivanje, dok se istovremeno zadržava mogućnost korištenja neizrazite logike i neizrazitog zaključivanja. Odgovori eksperata korišteni su kao ulazni skup podataka za formiranje pravila modela neizrazitog zaključivanja.

Definirana su ukupno 32 sustava (kandidata) za neizrazito zaključivanje kojima su pridijeljene odgovarajuće funkcije pripadnosti, definiran je oblik izlazne varijable te je definirana metoda za učenje (optimizaciju), kao i broj epoha. Svaki uspostavljeni neizraziti sustav testiran je na pouzdanost korištenjem RMSE metode. Najmanja greška učenja primijećena je općenito kod svih scenarija kod kojih je primijenjena hibridna metoda učenja i kod kojih je izlazna funkcija bila linearnog oblika. Korišten je hibridni model učenja, s tri epohe učenja. Izabrani model procjene urbane mobilnosti temeljem vrijednosti ulaznih pokazatelja urbane mobilnosti omogućava modeliranje urbane mobilnosti, odnosno generira izlaznu veličinu koju koristimo u svrhu procjene mobilnosti.

Rezultat modela ukazuje da mobilnost raste zajedno s pokazateljem broja putovanja, uz jedan interval u središtu funkcije, gdje procjena mobilnosti ima lagani pad u odnosu na broj putovanja. Rezultat pokazuje da je inicijalna postavka, po kojoj mobilnost generalno raste s brojem putovanja, uglavnom potvrđena, te su definirani intervali za koje to pravilo vrijedi, kao i intervali u kojima broj putovanja negativno utječe na mobilnost, odnosno uzrokuje njezinu stagnaciju ili pad. Možemo zaključiti da broj putovanja u određenim intervalima povećava ukupnu mobilnost te da postoji interval u kojem doprinos nije pozitivan, odnosno u kojem broj putovanja narušava ukupnu procjenu mobilnosti.

Rezultat modela ukazuje da općenito mobilnost pada s povećanjem vrijednosti pokazatelja trajanja putovanja, uz po jedan segment na početku i na kraju funkcije, gdje procjena mobilnosti ima lagani rast u odnosu na trajanje putovanja. Rezultat pokazuje da je inicijalna postavka, po kojoj mobilnost generalno pada s rastom trajanja putovanja, uglavnom potvrđena, te su definirani intervali za koje to pravilo vrijedi, kao i intervali u kojima trajanje putovanja pozitivno utječe na mobilnost, odnosno uzrokuje njezinu stagnaciju ili rast.

Rezultat modela ukazuje da mobilnost raste zajedno s pokazateljem prijednog putovanja (udaljenosti), ali samo do određene granice, nakon čega slijedi stagnacija i pad, a potom opet lagani rast. Rezultat pokazuje da je inicijalna postavka, po kojoj mobilnost uopćeno raste s prijednom udaljenošću, djelomično potvrđena, te su definirani intervali za koje to pravilo vrijedi, kao i intervali u kojima broj putovanja negativno utječe na mobilnosti, odnosno uzrokuje njezinu stagnaciju ili pad. Možemo zaključiti da udaljenost u određenom intervalu povećava ukupnu mobilnost, ali postoji prijelomna točka u kojoj njezin doprinos više nije pozitivan, jer postoje intervali u kojem udaljenost narušava ukupnu ocjenu mobilnosti.

Izlazni rezultat modela jest broj (veličina) koja pokazuje vrijednost procjene urbane mobilnosti za odgovarajući par urbanih područja (parcijalni indeks urbane mobilnosti), koji se potom u postupku procjene urbane mobilnosti koristi za izračun indeksa urbane mobilnosti cjelokupne urbane aglomeracije.

Validacija se provodi tijekom nekoliko koraka. Validacija ANFIS modela dio je procesa formiranja neizrazitog sustava zaključivanja. Osim toga, provedena je verifikacija algoritama koji su definirani u sklopu postupka procjene mobilnosti. Svrha ove verifikacije je provjera da definirani algoritmi i napisana programska podrška pravilno izračunavaju segment za koji su namijenjeni. Na kraju je napravljena validacija rezultata cjelokupnog modela procjene urbane mobilnosti, gdje nije utvrđeno odstupanje u odnosu na osnovni skup podataka.

Postupak procjene urbane mobilnosti primijenjen je na stvarnom javno dostupnom podskupu podataka izvedenog iz zapisa za naplatu telekomunikacijskih usluga iz javne pokretne komunikacijske mreže. Podaci se odnose na dio urbane aglomeracije grada Shenzena u Kini, a obuhvaćaju 480 baznih stanica koje pokrivaju površinu od otprilike 900 km².

Validacija modela pokazala je da prosječno odstupanje vrijednosti indeksa urbane mobilnosti za sve vremenske okvire u jednom danu iznosi 6 %, što se može uzeti prihvatljivom vrijednošću.

Istraživanjem je dokazana temeljna hipoteza ovoga znanstveno-istraživačkog rada koja kaže da se **urbana mobilnost stanovnika u gradskom okruženju u određenom vremenskom razdoblju može opisati indeksom urbane mobilnosti zasnovanom na informacijama o zabilježenim telekomunikacijskim aktivnostima korisnika u javnoj pokretnoj komunikacijskoj mreži**. Ispunjena je svrha znanstveno-istraživačkog rada te je dokazana mogućnost primjene podataka o telekomunikacijskim aktivnostima korisnika za potrebe

procjene urbane mobilnosti, identificirani su pokazatelji urbane mobilnosti, definiran je postupak njihova izračuna te je potom definiran model koji će iz vrijednosti tih pokazatelja dati procjenu urbane mobilnosti. Uspostavljen je postupak procjene urbane mobilnosti stanovništva kao kvantitativne veličine procesa urbanih migracija izazvanih društveno-ekonomskim aktivnostima.

Znanstveni doprinos je:

- Razvoj modela za procjenu urbane mobilnosti temeljene na telekomunikacijskim aktivnostima korisnika zabilježenih u javnim pokretnim komunikacijskim mrežama.
- Definiranje novog indeksa za procjenu urbane mobilnosti.

Aplikativni doprinos je:

- Uspostava modela neizrazitog zaključivanja temeljem tehnike strojnog učenja ANFIS-a za potrebe procjene urbane mobilnosti.
- Uspostava metodologije za identifikaciju i izračun pokazatelja temeljem odgovarajuće programske podrške, a u funkciji procjene urbane mobilnosti.
- Uspostava i definiranje postupka za izračun modela za procjenu urbane mobilnosti.
- Postavljanje temelja za korištenje indeksa urbane mobilnosti izvedenog iz zapisa o telekomunikacijskim aktivnostima korisnika za procjenu urbane mobilnosti.

Predloženi postupak procjene urbane mobilnosti namijenjen je domenskim stručnjacima (transport, logistika, ekologija, urbano planiranje) i znanstvenoj zajednici koja se bavi istraživanjem urbane mobilnosti i razvojem usluga vezanih za urbanu mobilnost. Metodologija je primjenjiva za identifikaciju urbane mobilnosti u gradovima, za praćenje trendova njezinih promjena, za identifikaciju slabosti i snage prometnog sustava te za identifikaciju ključnih ili kritičnih elementi. Rezultat modela pruža uvid u stanje urbane mobilnosti i omogućava bolje razumijevanje urbane mobilnosti te stvara temelj za unapređenje postojećih i stvaranje novih usluga u domeni urbane mobilnosti.

Predloženi model procjene mobilnosti, odnosno indeks urbane mobilnosti nije ciljano razvijan za određene gradove ili urbana područja, tako da njegova primjena u tom smislu nije ograničavajuća. Korištenje predloženog indeksa urbane mobilnosti omogućava objektivno i

usporedivo ocjenjivanje mobilnosti stanovnika urbanih aglomeracija u kojima postoje javne pokretne komunikacijske mreže, kao jedini izvor podataka o urbanoj mobilnosti.

Identificirana su i područja za daljnja istraživanja, odnosno za unapređenje postupka i modela procjene urbane mobilnosti. Unapređena su moguća u identificiranju novih pokazatelja mobilnosti iz istog skupa podataka. Također, potrebno je dodatno istraživati algoritme za poboljšanje točnosti određivanja izvora i odredišta putovanja. Dodatna istraživanja moguća su i kod pokazatelja prijedene udaljenosti, gdje je potrebno istražiti mogućnosti mapiranja kretanja korisnika na stvarnu, fizičku infrastrukturu (prometnice, pruge i slično). Također, moguće je izvršiti i dodatne prostorne analize, kako bi se utvrdilo pripadanje područja pokrivanja baznih stanica odgovarajućim administrativnim ili interesnim zonama, čime bi se izvršila primjerenija dekompozicija prostora. Dodatna istraživanja moguća su i u vidu identifikacije modalne razdiobe putovanja. Također, potrebno je dodatno istražiti i definirati koliki i koji vremenski okviri su prikladni za odgovarajuće namjene (upravljanje prometom, prostorno planiranje i slično), a sve u cilju kvalitetnije procjene urbane mobilnosti.

LITERATURA

- [1] European Commission, *Roadmap to a Single European Transport Area – towards a competitive and resource-efficient transport system*, Eur. Comm., vol. 226, p. 55, 2016.
- [2] European Commission, *Action Plan on Urban Mobility*, pp. 1–13, 2009.
- [3] European Commission, *Indicators for sustainable cities*, 2015.
- [4] Commission of the European Communities, *Green Paper - Towards a new culture for urban mobility*, Bruxelles, Belgija, 2007.
- [5] Zhang, D., J. Huang, Y. Li, F. Zhang, C. Xu, & T. He, *Exploring human mobility with multi-source data at extremely large metropolitan scales*, in *Proceedings of the 20th annual international conference on Mobile computing and networking - MobiCom '14*, 2014, pp. 201–212.
- [6] Lopes, J., J. Bento, E. Huang, C. Antoniou, & M. Ben-Akiva, *Traffic and Mobility Data Collection for Real- Time Applications*, *13th Int. IEEE Conf. Intell. Transp. Syst.*, vol. 8, pp. 216–223, 2010.
- [7] Chen, C., J. Ma, Y. Susilo, Y. Liu, & M. Wang, *The promises of big data and small data for travel behavior (aka human mobility) analysis*, *Transp. Res. Part C*, vol. 68, pp. 285–299, 2016.
- [8] Prabha, R. & M. G. Kabadi, *Overview of Data Collection Methods for Intelligent Transportation Systems*, *Int. J. Eng. Sci.*, vol. 5, no. 3, pp. 16–20, 2016.
- [9] González, M. C., C. A. Hidalgo, & A.-L. Barabási, *Understanding individual human mobility patterns*, *Nature*, vol. 453, no. June, pp. 779–782, 2008.
- [10] Wang, H., F. Calabrese, G. Di Lorenzo, & C. Ratti, *Transportation mode inference from anonymized and aggregated mobile phone call detail records*, *IEEE Conf. Intell. Transp. Syst. Proceedings, ITSC*, pp. 318–323, 2010.
- [11] Frias-Martinez, V., C. Soguero, & E. Frias-Martinez, *Estimation of urban commuting patterns using cellphone network data*, *Proc. ACM SIGKDD Int. Work. Urban Comput. - UrbComp '12*, p. 9, 2012.
- [12] Calabrese, F., M. Diao, G. Di Lorenzo, J. Ferreira, & C. Ratti, *Understanding individual mobility patterns from urban sensing data: A mobile phone trace example*, *Transp. Res.*

Part C, vol. 26, p. 301313, 2013.

- [13] Chen, C., L. Bian, & J. Ma, *From traces to trajectories: How well can we guess activity locations from mobile phone traces?*, *Transp. Res. Part C Emerg. Technol.*, vol. 46, pp. 326–337, 2014.
- [14] Çolak, S., L. P. Alexander, B. G. Alvim, S. R. Mehndiretta, & M. C. Gonzalez, *Analyzing Cell Phone Location Data for Urban Travel: Current Methods, Limitations and Opportunities*, *TRB 2015 Annu. Meet.*, pp. 1–17, 2015.
- [15] Alberti, M., *Measuring urban sustainability*, *Environmental Impact Assessment Review*, vol. 16, no. 4–6. pp. 381–424, 1996.
- [16] Marsden Sotirios, G. T., *Improved indicators for sustainable transport and planning: Measuring wider economic benefits of transport - A case study in good practice for indicator selection*. Leeds, Velika Britanija, Institute for Transport Studies University of Leeds, 2008.
- [17] Anastasi, G., Antonelli, M., Bechini, A., Brienza, S., D’Andrea, E., *Urban and social sensing for sustainable mobility in smart cities*, in *Proceedings of Sustainable Internet and ICT for Sustainability (SustainIT)*, 2013.
- [18] Huang, L., Jianguo, W., Yan, L., *Defining and measuring urban sustainability: a review of indicator*, *Landsc. Ecol.*, vol. 30, pp. 1175–1193, 2015.
- [19] Litman, T., *Measuring transportation: Traffic, mobility and accessibility*, *ITE J. (Institute Transp. Eng.)*, vol. 73, no. 10, pp. 28–32, 2003.
- [20] Wesolowski, A., N. Eagle, A. M. Noor, R. W. Snow, & C. O. Buckee, *The impact of biases in mobile phone ownership on estimates of human mobility*, no. February, 2013.
- [21] Cox, W., *Urban access indicators*, no. July. Austin, SAD, Demographia, 2007.
- [22] Kaparias, I. & M. G. H. Bell, *Key Performance Indicators for traffic management and Intelligent Transport Systems*, London, 2011.
- [23] Frei, F., *Sampling mobility index: Case study in Assis-Brazil*, *Transp. Res. Part A Policy Pract.*, vol. 40, no. 9, pp. 792–799, 2006.
- [24] Kuhlke, O., *Mobilities, Networks, Geographies*, *Prof. Geogr.*, vol. 60, no. 3, pp. 429–

430, Aug. 2008.

- [25] Brčić, D. & M. Ševrović, *Logistika prijevoza putnika*. Zagreb, Fakultet prometnih znanosti Sveučilišta u Zagrebu, 2012.
- [26] Hanson, S. & G. Giuliano, *The Geography of urban transportation*. London, Velika Britanija, The Guilford Press, 2004.
- [27] Gillis, D., I. Semanjski, & D. Lauwers, *How to monitor sustainable mobility in cities? Literature review in the frame of creating a set of sustainable mobility indicators*, *Sustain.*, vol. 8, no. 1, pp. 1–30, 2016.
- [28] Casey, J., J. L. Norwood, & National Research Council, *Key transportation indicators*. Washington, National Academy Press, 2002.
- [29] Costa, M. S., A. N. R. Silva, & R. A. R. Ramos, *Sustainable urban mobility: a comparative study and the basis for a management system in Brazil and Portugal*, *Urban Transp. XI Urban Transp. Environ. 21th century*, vol. 77, pp. 323–332, 2005.
- [30] Brčić, D. & M. Šoštarić, *Parkiranje i garaže*. Zagreb, Fakultet prometnih znanosti Sveučilišta u Zagrebu, 2012.
- [31] Rashidy, E. L., R. Ahmed, G. Muller, & S. EL Rashidy, Rawia Ahmed and Grant Muller, *A network mobility indicator using a fuzzy logic approach*, *TRB 93rd Annu. Meet. Compend. Pap. Transp. Res. Board*, vol. 44, no. 0, pp. 1–14, 2014.
- [32] Gudmundsson, H., *Making concepts matter: sustainable mobility and indicator systems in transport policy**, *Int. Soc. Sci. J.*, vol. 55, no. 176, pp. 199–217, 2003.
- [33] Litman, T., *Developing Indicators for Comprehensive and Sustainable Transport Planning*, *Transp. Res. Rec.*, vol. 2017, no. 1, pp. 10–15, 2008.
- [34] Litman, T., *Well Measured - Developing Indicators for Sustainable and Livable Transport Planning*. Melbourne, Victoria Transport Policy Institute, 2015.
- [35] Kaparias, I. et al., *Development and Application of an Evaluation Framework for Urban Traffic Management and Intelligent Transport Systems*, *Procedia - Soc. Behav. Sci.*, vol. 48, pp. 3102–3112, 2012.
- [36] Abramović, B. & D. Šipuš, *Prijedlog za poboljšanje mobilnosti na području Grada Siska, Željeznice 21*, vol. 14, no. 4, pp. 93–98, 2015.

- [37] Audenhove, V. F.-J., O. Korniichuk, L. Dauby, & J. Pourbaix, *The Future of Urban Mobility 2 . 0*, 2014.
- [38] Zelenika, R., *Metodologija i tehnologija izrade znanstvenog i stručnog djela*, IV. Rijeka, Ekonomski fakultet Sveučilišta u Rijeci, 2000.
- [39] Yousaf M. Shah, *Developing Key Performance Indicators to assess Urban Transportation Systems*, McGill University, 2012.
- [40] Wu, J. & T. Wu, *Sustainability Indicators and Indices*. London, Velika Britanija, Imperial College Press, 2012.
- [41] Motta, G., Sacco, D., Ma, T., You, L., Liu, T., *Personal Mobility Service System in Urban Areas*, in *Proceedings of 2015 IEEE Symposium on Service-Oriented System Engineering (SOSE)*, 2015.
- [42] Marsden, G. & C. Snell, *The role of indicators, targets and monitoring in decision-support for transport*, *Eur. J. Transp. Infrastruct. Res.*, vol. 9, no. 3, pp. 219–236, 2009.
- [43] Zietsman, J. & L. R. Rilett, *Sustainable Transportation: Conceptualization and Performance Measures*, vol. 7, no. 2. Austin, SAD, Texas Transportation Institute, 2002.
- [44] Mameli, F. & G. Marletto, *A selection of indicators for monitoring sustainable urban mobility policies*, *Trasp. Ambient. e Territ. La Ric. di un nuovo equilibrio*, Milano, 2009.
- [45] Toth-Szabo, Z. & A. Várhelyi, *Indicator Framework for Measuring Sustainability of Transport in the City*, *Procedia - Soc. Behav. Sci.*, vol. 48, pp. 2035–2047, 2012.
- [46] Nicolas, J. P., P. Pochet, & H. Poimboeuf, *Towards sustainable mobility indicators: Application to the Lyons conurbation*, *Transp. Policy*, vol. 10, no. 3, pp. 197–208, 2003.
- [47] Cianfano, M., Gentile, G., Nussio, F., Tuffanelli, G., Rossi, P., Vergini, R., & Terenzi, G., *Transport and Mobility Indicators Based on Traffic Measures – Good Practices Guidebook*, 2008.
- [48] Imran, M. & N. Low, *Time to Change the Old Paradigm: Promoting Sustainable Urban Transport*, *World Transp. Policy Pract.*, vol. 9, no. 2, pp. 32–39, 2003.
- [49] Barker, W., *Can a Sustainable Transportation System Be Developed for San Antonio, Texas*, *Transp. Res. Rec. J. Transp. Res. Board*, vol. 1924, pp. 120–128, Jan. 2005.
- [50] EYGM, *Urban mobility redefined*, 2015.

- [51] Stantchev, D. & T. Rye, *Findings and Recommendations from CIVITAS CAPITAL Advisory Groups Data and Statistics*, Edinburgh, 2015.
- [52] Cortright, J., *Measuring Urban Transportation Performance*, no. September. Chicago, 2010.
- [53] Murr, S. & S. Phillips, *The Proposal of a Shared Mobility City Index to Support Investment Decision Making for Carsharing*, *World Acad. Sci. Eng. Technol. Int. J. Soc. Behav. Educ. Econ. Bus. Ind. Eng.*, vol. 10, no. 2, pp. 610–617, 2016.
- [54] National Research Council, *Highway Capacity Manual (HCM)*. Washington DC, SAD, Transportation Research Board (TRB), National Academies of Science, 2010.
- [55] Dadić, Ivan; Kos, Goran; Ševrović, M., *Teorija prometnog toka*. Zagreb, 2014.
- [56] Sakai, T., K. Yamada-Kawai, H. Matsumoto, & T. Uchida, *New measure of the level of service for basic expressway segments incorporating customer satisfaction*, *Procedia - Soc. Behav. Sci.*, vol. 16, pp. 57–68, 2011.
- [57] Morfoulaki, M., Y. Tyrinopoulos, & G. Aifadopoulou, *Estimation of Satisfied Customers in Public Transport Systems: A New Methodological Approach*, *J. Transp. Res. Forum*, vol. 46, no. 1, pp. 63–72, 2007.
- [58] Allen, I. E. & C. a. Seaman, *Likert scales and data analyses*, *Quality Progress*, vol. 40, no. 7. pp. 64–65, 2007.
- [59] Narodne novine, *Zakon o elektroničkim komunikacijama*, vol. 71, no. 14, 2014.
- [60] ETSI & 3GPP, *3GPP TS 32.240: Charging architecture and principles*, 2016.
- [61] Filić, M., R. Filjar, & K. Vidović, *Graphical presentation of Origin-Destination matrix in R statistical environment*, in *36. skup o prometnim sustavima s međunarodnim sudjelovanjem Korema „Automatizacija u prometu 2016“*, 2016.
- [62] Liu, L., A. Biderman, & C. Ratti, *Urban Mobility Landscape : Real Time Monitoring of Urban Mobility Patterns*, *Proc. 11th Int. Conf. Comput. Urban Plan. Urban Manag.*, pp. 1–16, 2009.
- [63] Filjar, R., M. Filić, A. Lučić, K. Vidović, & D. Šarić, *Anatomy of Origin-Destination matrix derived from GNSS alternatives*, *Coordinates*, vol. XII, no. 10, pp. 8–10, 2016.
- [64] ETSI, *3GPP TS 32.240 V10.0.0 (2010-12) - 3rd Generation Partnership Project*;

- Technical Specification Group Services and System Aspects; Telecommunication management; Charging management; Charging architecture and principles (Release 10)*, vol. 0, pp. 0–46, 2016.
- [65] Križan, T., M. Brakus, & D. Vukelić, *In-situ anonymization of big data*, 2015 38th Int. Conv. Inf. Commun. Technol. Electron. Microelectron. MIPRO 2015 - Proc., no. May, pp. 292–298, 2015.
 - [66] Ratti, C., A. Sevtsuk, S. Huang, & R. Pailer, *Mobile Landscapes: Graz in Real Time, Locat. Based Serv. TeleCartography*, no. October 2005, pp. 433–444, 2007.
 - [67] Ratti, C., F. Rojas, F. Calabrese, F. Dal Fiore, & S. Krishnan, *Real Time Rome, Urban_Trans_Formation. Proc. Holcim Forum Sustain. Constr.*, 2007.
 - [68] Williams, N. E., T. A. Thomas, M. Dunbar, N. Eagle, & A. Dobra, *Measures of human mobility using mobile phone records enhanced with GIS data*, *PLoS One*, vol. 10, no. 7, pp. 1–16, 2015.
 - [69] Calabrese, F. & G. Di Lorenzo, *Estimating Origin- Destination Flows using Mobile phone Location Data*, *Cell*, vol. 10, pp. 36–44, 2011.
 - [70] Dash, M. et al., *CDR-To-MoVis: Developing a Mobility Visualization System from CDR data*, *Proc. - Int. Conf. Data Eng.*, vol. May, pp. 1452–1455, 2015.
 - [71] Pulselli, R. M., F. M. Pulselli, C. Ratti, & E. Tiezzi, *Dissipative Structures for Understanding Cities : Resource Flows and Mobility Patterns*, 2005, pp. 271–279, 2005.
 - [72] Reades, J., F. Calabrese, A. Sevtsuk, & C. Ratti, *Cellular census: Explorations in Urban data collection*, *IEEE Pervasive Comput.*, vol. 6, no. 3, pp. 30–38, 2007.
 - [73] Trevisani, E. & A. Vitaletti, *Cell-ID location technique, limits and benefits: An experimental study*, *Proc. - IEEE Work. Mob. Comput. Syst. Appl. WMCSA*, pp. 51–60, 2004.
 - [74] Ahas, R., A. Aasa, Ü. Mark, T. Pae, & A. Kull, *Seasonal tourism spaces in Estonia: Case study with mobile positioning data*, *Tour. Manag.*, vol. 28, no. 3, pp. 898–910, 2007.
 - [75] Candia, J., M. C. González, P. Wang, T. Schoenharl, G. Madey, & A.-L. Barabási, *Uncovering individual and collective human dynamics from mobile phone records*, *J. Phys. A Math. Theor*, vol. 41, pp. 224015–11, 2008.

- [76] Caceres, N., J. P. Wideberg, & F. G. Benitez, *Review of traffic data estimations extracted from cellular networks*, *IET Intell. Transp. Syst.*, vol. 2, no. 3, p. 179, 2008.
- [77] Caceres, N., J. P. Wideberg, & F. G. Benitez, *Deriving origin–destination data from a mobile phone network*, *IET Intell. Transp. Syst.*, vol. 1, no. 1, p. 15, 2007.
- [78] Chaoming, S. *et al.*, *Limits of Predictability in Human Mobility*, *Science* (80-.), vol. 327, no. 5968, pp. 1018–1021, 2010.
- [79] Bengtsson, L., X. Lu, & R. Garfield, *Internal Population Displacement in Haiti, Earthquake*, no. March, 2010.
- [80] Thiessenhusen, K. U., R. P. Schäfer, & T. Lang, *Traffic data from cell phones: a comparison with loops and probe vehicle data*, *Inst. Transp. Res. Ger. Aerosp. Center, Ger.*, 2003.
- [81] Ygnace, J.-L., *Travel Time/Speed Estimates on the French Rhone Corridor Network Using Cellular Phones as Probes, Final report, Serti V Program STRIP*, *Inst. Natl. Rech. sur les Transp. leur Secur.*, 2001.
- [82] Iqbal, M. S., C. F. Choudhury, P. Wang, & M. C. González, *Development of origin-destination matrices using mobile phone call data*, *Transp. Res. Part C Emerg. Technol.*, vol. 40, pp. 63–74, 2014.
- [83] Wang, P., T. Hunter, A. M. Bayen, K. Schechtner, & M. C. González, *Understanding road usage patterns in urban areas.*, *Sci. Rep.*, vol. 2, p. 1001, 2012.
- [84] Alexander, L., S. Jiang, M. Murga, & M. C. González, *Origin-destination trips by purpose and time of day inferred from mobile phone data*, *Transp. Res. Part C Emerg. Technol.*, vol. 58, pp. 240–250, 2015.
- [85] Vidović, K., A. Lučić, & D. Šarić, *Methodology of O-D Matrix determination from telecommunication charging data records*, in *36. skup o prometnim sustavima s međunarodnim sudjelovanjem Korema „Automatizacija u prometu 2016“*, 2016.
- [86] Liao, S. H., *Expert system methodologies and applications-a decade review from 1995 to 2004*, *Expert Syst. Appl.*, vol. 28, no. 1, pp. 93–103, 2005.
- [87] Zhang, D., J. Zhao, F. Zhang, & T. He, *UrbanCPS: a Cyber-Physical System based on Multi-source Big Infrastructure Data for Heterogeneous Model Integration*, in *Proceedings of the ACM/IEEE Sixth International Conference on Cyber-Physical*

Systems - ICCPS '15, 2015, pp. 238–247.

- [88] Watson, F., *Text-Book on Spherical Astronomy*, vol. 86, no. 2237. 1937.
- [89] Brčić, D., L. Šimunović, & M. Slavulj, *Upravljanje prijevoznom potražnjom u gradovima*. Fakultet prometnih znanosti, 2016.
- [90] Ross, T. J., *Fuzzy Logic with Engineering Applications*, vol. 222. 2004.
- [91] Kovačić, Z. & S. Bogdan, *Inteligentno upravljanje sustavima - Tema 1 - Neizraziti sustavi*. Zagreb, Fakultet elektrotehnike i računarstva, 2000.
- [92] *Hrvatska enciklopedija, Leksikografski zavod Miroslav Krleža*. [Online]. Available: <http://www.enciklopedija.hr/natuknica.aspx?id=68389>. [Accessed: 18-Apr-2017].
- [93] Dernoncourt, F., *Introduction to Fuzzy Logic Control*, no. January, Boston, Massachusetts Institute of Technology, 2010, pp. 1–12.
- [94] Yager, R. R., *An introduction to Fuzzy set theory, Appl. Fuzzy Set Theory Hum. Factors*, pp. 29–39, 1986.
- [95] Ibrahim, A., *Fuzzy logic for embedded systems applications*. New York, SAD, Elsevier, 2004.
- [96] Lončar, D., *Primjena neizrazite logike u regulacijskom sustavu termoenergetskog bloka*, Sveučilište u Zagrebu, 2001.
- [97] Lisjak, D., *Primjena metode umjetne inteligencije pri izboru materijala*, Sveučilište u Zagrebu, 2004.
- [98] Bonato, J., *Methods of Artificial Intelligence – Fuzzy Logic*, in *DAAAM INTERNATIONAL SCIENTIFIC BOOK 2013*, 2013, pp. 849–856.
- [99] Jang, J. S. R., *ANFIS: Adaptive-Network-Based Fuzzy Inference System*, *IEEE Trans. Syst. Man Cybern.*, vol. 23, no. 3, pp. 665–685, 1993.
- [100] Al-hmouz, A., J. Shen, S. Member, R. Al-hmouz, & J. Yan, *Modeling and Simulation of an Adaptive Neuro-Fuzzy Inference System (ANFIS) for Mobile Learning*, *IEEE Trans. Learn. Technol.*, vol. 5, no. 3, pp. 226–237, 2012.
- [101] Jang, J. S. R. & C. T. Sun, *Neuro-Fuzzy Modeling and Control*, *Proc. IEEE*, vol. 83, no. 3, pp. 378–406, 1995.
- [102] Jang, J. R., C.-T. Sun, & E. Mizutani, *Neuro-Fuzzy and Soft Computing*, pp. 1–614, 1997.

- [103] Gorzalczany, M. B., *Computational Intelligence Systems and Applications*. 2002.
- [104] Foong, K. C., C. T. Chee, & L. S. Wei, *Adaptive network fuzzy inference system (ANFIS) handoff algorithm*, *Proc. - 2009 Int. Conf. Futur. Comput. Commun. ICFCC 2009*, pp. 195–198, 2009.
- [105] Benšić, M. & N. Šuvak, *Primijenjena statistika*. Osijek, Sveučilište J. J. Strossmayera u Osijeku, 2013.
- [106] McKillup, S., *Statistics Explained: An Introductory Guide for Life Scientists*. New York, SAD, Cambridge University Press, 2012.
- [107] Turevskiy, A., *Fuzzy Logic Toolbox User's Guide*. Natick, SAD, MathWorks, 2012.
- [108] Vaidhehi, V., *The role of Dataset in training ANFIS System for Course Advisor*, *Int. J. Innov. Res. Adv. Eng.*, vol. 1, no. 6, pp. 249–253, 2014.
- [109] Sarle, W. S., *Stopped Training and Other Remedies for Overfitting*, *Proc. 27th Symp. Interface Comput. Sci. Stat.*, pp. 352–360, 1995.
- [110] Vujović, I., *Modeliranje i simuliranje u elektrotehnici: Matlab / Simulink*. Split, Sveučilište u Splitu, Pomorski fakultet, 2014.
- [111] Filo, G., *Modelling of Fuzzy Logic Control System Using the Matlab Simulink Program*, *Tech. Trans.*, vol. 7, no. 3, pp. 13–15, 2010.
- [112] Encyclopædia Britannica Inc., *Encyclopaedia Britannica, Encyclopædia Britannica Online*. [Online]. Available: <https://www.britannica.com/place/Shenzhen>. [Accessed: 12-May-2017].

POPIS SLIKA

Slika 1. Elementi procesa ocjenjivanja mobilnosti, obrada autora temeljem [41]	15
Slika 2. Pokazatelji kvalitete prometne usluge i razine mobilnosti.....	35
Slika 3. Primjer podjele prostora na heksagonalne ćelije (ilustracija)	40
Slika 4. Primjer podjele prostora korištenjem rastera polja (ilustracija).....	40
Slika 5. Dekompozicija prostora korištenjem Voronojevog postupka (ilustracija)	41
Slika 6. Logička arhitektura sustava naplate i tijek informacija u javnoj pokretnoj telefonskoj mreži [64]	41
Slika 7. Vizualizacija telekomunikacijskih aktivnosti korisnika u gradu Grazu [66]	45
Slika 8. Hodogram aktivnosti određivanja indeksa urbane mobilnosti.....	54
Slika 9. Primjer strukturiranog i depersonaliziranog podskupa podataka koji se koristi za analizu. Podaci preuzeti od [87].	55
Slika 10. Dekompozicija prostora u Voronojeve ćelije na primjeru grada Shenzena na podlozi Google Maps [61].....	57
Slika 11. Primjer simuliranih podataka koji su izlaz iz algoritma, kao tablice broja putovanja, tablice udaljenosti i tablice trajanja putovanja za tri vremenska intervala O1 do O3	71
Slika 12. Primjer matrice najbrojnijih putovanja	71
Slika 13. Primjer normalizirane matrice putovanja.....	71
Slika 14. Izračun matrice najdužih putovanja	72
Slika 15. Izračun normalizirane matrice trajanja putovanja.....	72
Slika 16. Primjer cjelokupne mreže, ukupne dužine cjelokupne mreže i normaliziranih veličina	72
Slika 17. Izračun ukupne mobilnosti	75
Slika 18. Izračun udjela u ukupnoj mobilnosti.....	75
Slika 19. Međusobni odnos pokazatelja i veličina u procesu izračuna indeksa urbane mobilnosti.....	76
Slika 20. Udio ukupnih dnevnih putovanja tijekom karakterističnog dana (u %) [26].....	79
Slika 21. Proces formiranja scenarija za procjenu urbane mobilnosti	88
Slika 22. Primjer odgovora jednog od eksperata.....	89
Slika 23. Detalji s radionica s ekspertima	90
Slika 24. Odnos minimalne, prosječne i maksimalne ocjene mobilnosti za svako anketno pitanje	92
Slika 25. Histogramski prikaz rezultata ankete	93
Slika 26. Shematski prikaz elemenata neizrazitog sustava	96
Slika 27. Karakteristični elementi funkcije pripadnosti	98
Slika 28. Shematski prikaz najčešćih funkcija pripadnost	98
Slika 29. Funkcija pripadnosti tipa trokut	99
Slika 30. Preklapanje skupova unutar univerzalnog skupa	99
Slika 31. Defazifikacija korištenjem metode težišta	102
Slika 32. Arhitektura ANFIS mreže, ilustracija autora temeljem [99].....	104

Slika 33. Hodogram modeliranja ANFIS modela	109
Slika 34. Primjer dijela odgovorenog anketnog upitnika sa deskriptivnim vrijednostima	110
Slika 35. Primjer dijela odgovorenog anketnog upitnika u kojem su deskriptivne vrijednosti zamijenjene numeričkim varijablama	110
Slika 36. Normalizacija podataka u potpaketu Rattle	111
Slika 37. Podjela podataka na skup za učenje, validaciju i provjeru modela.....	111
Slika 38. Primjer vrijednosti podataka prije (četiri kolone s lijeve strane) i nakon normalizacije (četiri kolone s desne strane)	111
Slika 39. Sučelje programskog alata Matlab	112
Slika 40. Učitavanje podataka	112
Slika 41. Sučelje za ANFIS u programskom alatu Matlab.....	112
Slika 42. Učitavanje podataka po skupovima	112
Slika 43. Izbor funkcije pripadnosti	115
Slika 44. Prikaz opisa intervala funkcije pripadnosti tipa trapez	115
Slika 45. Grafički prikaz inicijalnog modela indeksa urbane mobilnosti	117
Slika 46. Pogreška učenja u ovisnosti o broju epoha za sustav neizrazitog zaključivanja broj	119
Slika 47. Struktura ANFIS modela.....	120
Slika 48. Grafički prikaz pravila u inicijalnom modelu neizrazitog zaključivanja	120
Slika 49. Prikaz dijela pravila raspisanih u tekstualnom obliku.....	121
Slika 50. Skup podataka za učenje	121
Slika 51. Skup podataka za validaciju.....	122
Slika 52. Skup podataka za provjeru	122
Slika 53. Odnos skupa podataka za učenje i skupa podataka za validaciju modela.....	123
Slika 54. Odnos skupa podataka za učenje i skupa podataka za validaciju modela.....	124
Slika 55. Grafički prikaz pravila po završetku procesa učenja modela.....	127
Slika 56. Odnos pokazatelja prijedene udaljenosti i procjene mobilnosti (prikaz iz programskog alata Matlab).....	131
Slika 57. Odnos pokazatelja trajanja putovanja i procjene mobilnosti (prikaz iz programskog alata Matlab).....	132
Slika 58. Odnos pokazatelja broja putovanja i procjene mobilnosti (prikaz iz programskog alata Matlab).....	133
Slika 59. Rezultat modela: odnos pokazatelja trajanja putovanja i broja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab)(1).....	134
Slika 60. Rezultat modela: odnos pokazatelja trajanja putovanja i broja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab) (2).....	134
Slika 61. Rezultat modela: odnos pokazatelja udaljenosti i broja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab)(1).....	135
Slika 62. Rezultat modela: odnos pokazatelja udaljenosti i broja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab) (2).....	135
Slika 63. Rezultat modela: odnos pokazatelja trajanja putovanja i udaljenosti u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab) (1).....	136

Slika 64. Rezultat modela: odnos pokazatelja udaljenosti i trajanja putovanja u odnosu na procjenu mobilnosti (prikaz iz programskog alata Matlab) (2).....	136
Slika 65. Blok shema modela za izračun indeksa urbane mobilnosti u programskom okružju Simulink	139
Slika 66. Detaljni prikaz modela u ANFIS-u	140
Slika 67. Grafički prikaz odnosa vrijednosti ulaznih pokazatelja i vrijednosti procjene mobilnosti.....	140
Slika 68. Hodogram aktivnosti i pripadajući programski alati.....	141
Slika 69. Primjer programskog koda unutar jezika R	142
Slika 70. Normalizirane matrice putovanja, trajanja putovanja i nor. dužine mreže (udaljenosti) -simulirani podaci za vremenski okvir O1	143
Slika 71. Normalizirane matrice putovanja, trajanja putovanja i nor. dužine mreže (udaljenosti) – simulirani podaci za vremenski okvir O3	143
Slika 72. Odnos pokazatelja i parcijalnog indeksa urbane mobilnosti za okvir O1	144
Slika 73. Odnos pokazatelja i parcijalnog indeksa urbane mobilnosti za okvir O3	144
Slika 74. Vrijednosti pIM-a prije i poslije svođenja na interval [0,1] za okvir O1	144
Slika 75. Segment podskupa podataka iz zapisa za naplatu korišten za procjenu mobilnosti. Podaci iz [87].	146
Slika 76. Segment tablice baznih stanica	146
Slika 77. Položaj baznih stanica i identifikacijska oznaka na dijelu obuhvaćenog područja	146
Slika 78. Dekompozicija prostora na Voronojeve ćelije (lijevo) i preklapanje s kartografskom podlogom Google Maps (desno).....	148
Slika 79. Udaljenost između dvije najudaljenije bazne stanice (36 i 476, označene žutom bojom) iznosi 42,9 km.....	148
Slika 80. Identifikacija dvije migracije korisnika identifikacijske oznake „005672110“ (ilustracija)	150
Slika 81. Ukupan broj migracija prije filtriranja po vremenskim okvirima (broj migracija)	150
Slika 82. Broj migracija poslije filtriranja po vremenskim okvirima (broj migracija)	151
Slika 83. Ilustracija količine podataka korištene za procjenu mobilnosti (zeleno polje) i skupa podataka za validaciju (crveno polje)	151
Slika 84. Suma svih srednjih vrijednosti trajanja putovanja po vremenskim okvirima (u satima)	152
Slika 85. Najduža trajanja pojedinih putovanja po vremenskom okviru	153
Slika 86. Detalj iz tablice svih udaljenosti između svih parova baznih stanica (prvih 10 od ukupno 480 redaka i stupaca).....	154
Slika 87. Detalj iz tablice udaljenosti između svih parova baznih stanica u kojima je ostvareno putovanje u karakterističnom danu (prvih 25 od ukupno 480 redaka i stupaca) ...	154
Slika 88. Najduža dionica mreže na kojoj je ostvareno putovanje po vremenskom okviru	155
Slika 89. Ukupna duljina mreže na kojoj je ostvareno putovanje po vremenskim okvirima	155

Slika 90. Detalj iz tablice normaliziranih udaljenosti za vremenski okvir O1	155
Slika 91. Vrijednosti PIM-a za okvir O1	158
Slika 92. Vrijednosti PIM-a za okvir O2	158
Slika 93. Vrijednosti PIM-a za okvir O3	158
Slika 94. Vrijednosti PIM-a za okvir O4	158
Slika 95. Vrijednosti PIM-a za okvir O5	158
Slika 96. Vrijednosti PIM-a za okvir O6	158
Slika 97. Vrijednosti PIM-a za okvir O7	158
Slika 98. Vrijednosti PIM-a za okvir O8	158
Slika 99. Odstupanje vrijednosti indeksa urbane mobilnosti iz osnovnog skupa u odnosu na podatke korištene za validaciju	159
Slika 100. Usporedba vrijednosti indeksa urbane mobilnosti iz osnovnog skupa i s podacima za validaciju (1)	160
Slika 101. Segment tablice ukupne mobilnosti za sumu vrijednosti okvira O1-O8	161
Slika 102. Vizualizacija cjelokupne tablice urbane mobilnosti (480x480) za sumu vrijednosti okvira O1-O8	161

POPIS TABLICA

Tablica 1. Popis izvora podataka koji se mogu koristiti u svrhu procjene mobilnosti	16
Tablica 2. Pregled transportnih pokazatelja	23
Tablica 3. Pregled ekonomskih pokazatelja	24
Tablica 4. Pregled društvenih pokazatelja	24
Tablica 5. Pregled okolišnih pokazatelja	25
Tablica 6. Pregled ostalih pokazatelja	26
Tablica 7. Odnos razine usluge i zadovoljstva korisnika	34
Tablica 8. Odnos razine usluge i ocjene mobilnosti	35
Tablica 9. Format tablice koja je rezultat konverzije ulaznih podataka	56
Tablica 10. Tablica baznih stanica	56
Tablica 11. Tablica udaljenosti između baznih stanica (primjer)	59
Tablica 12. Tablica putovanja (primjer)	60
Tablica 13. Tablica putovanja bez identiteta korisnika (primjer)	61
Tablica 14. Identificirana putovanja sa pridijeljenim udaljenostima između parova baznih stanica (primjer)	61
Tablica 15. Tablica brzina za svako pojedino putovanje (primjer)	62
Tablica 16. Identificiranje i filtriranje zapisa koji ne odgovaraju vremenskim i prostornim pretpostavkama (primjer)	63
Tablica 17. Uklanjanje putovanja koji ne zadovoljavaju uvjete vezane za brzinu (primjer)	63
Tablica 18. Primjer matrice putovanja (O-D matrica) prikazane u tabličnom obliku (primjer)	64

Tablica 19. Vrijednosti pokazatelja udaljenosti prikazani u tabličnom obliku (primjer)...	65
Tablica 20. Primjer tablice vremena putovanja (primjer)	66
Tablica 21. Udio dnevnih putovanja, obrada autora temeljem [26]	80
Tablica 22. Pokazatelj broja putovanja	80
Tablica 23. Vremenski okviri (doba dana)	81
Tablica 24. Pokazatelj trajanja putovanja	82
Tablica 25. Pokazatelj trajanja putovanja (relativna vrijednost)	83
Tablica 26. Pokazatelj prijeđenog puta (udaljenosti)	84
Tablica 27. Pokazatelj prijeđenog puta (udaljenosti)	84
Tablica 28. Razina mobilnosti	85
Tablica 29. Vrijednosti pokazatelja	86
Tablica 30. Popis scenarija za procjenu mobilnosti	88
Tablica 31. Analiza rezultata anketnog upitnika	91
Tablica 32. Slojevi ANFIS mreže [99], [101], [102]	104
Tablica 33. Broj parova podataka za pojedinu fazu modeliranja	111
Tablica 34. Funkcije pripadnosti [107]	114
Tablica 35. Ulazna varijabla „Broj putovanja“ i pripadajući neizraziti skupovi u inicijalnom modelu neizrazitog zaključivanja	116
Tablica 36. Ulazna varijabla „Trajanje putovanja“ i pripadajući neizraziti skupovi u inicijalnom modelu neizrazitog zaključivanja	116
Tablica 37. Ulazna varijabla „Udaljenost“ i pripadajući neizraziti skupovi u inicijalnom modelu neizrazitog zaključivanja	117
Tablica 38. Usporedba vrijednosti intervala ulaznih funkcija pripadnosti prije i poslije provođenja učenja modela	125
Tablica 39. Intervali izlazne funkcije u inicijalnom modelu neizrazitog zaključivanja... ..	126
Tablica 40. Prikaz rezultata greške učenja i validacije modela u ovisnosti o postavkama sustava za neizrazito zaključivanje	129
Tablica 41. Segment tablice udaljenosti između baznih stanica	147
Tablica 42. Vremenski okviri	149
Tablica 43. Broj parova baznih stanica nakon filtriranja	156
Tablica 44. Segment tablice za vremenski okvir O1 sa pokazateljima i izračunatim vrijednostima parcijalnog indeksa urbane mobilnosti	157
Tablica 45. Deset parova baznih stanica sa najvećim iIM za vremenske okvire O1-O8 ..	157
Tablica 46. Vrijednosti indeksa urbane mobilnosti po vremenskim okvirima za osnovni skup podataka, te za skup podataka koji je korišten za validaciju	159
Tablica 47. Ukupna količina mobilnosti za svaki vremenski okvir	160
Tablica 48. Tablica sa najmanjim i najvećim vrijednostima koeficijenta α_i, j	162

ŽIVOTOPIS



Krešimir Vidović rođen je 7. listopada 1980. godine u Pakracu. Osnovnu i srednju školu (X. gimnazija - opći smjer) završio je u Zagrebu. Na Fakultetu prometnih znanosti Sveučilišta u Zagrebu završio je smjer „Pošta i telekomunikacije” te je diplomirao s izvrsnim uspjehom 2006. godine, stekavši naziv diplomirani inženjer prometa. Dobitnik je Rektorove nagrade za rad "Model višekriterijskog odlučivanja pri izboru operatora mobilne telefonije u Republici Hrvatskoj". Od 2003. do 2006. godine bio je glavni urednik studentskog časopisa Fakulteta prometnih znanosti „PROM“ te voditelj studentske međunarodne suradnje. Krajem studija započinje suradnički odnos na Institutu prometa i veza u Zagrebu, a tamo se i zapošljava 2007. godine i radi do 2010. godine. Na poziciji stručnog suradnika radi na znanstveno-istraživačkim poslovima u prometu, bavi se prometnim planiranjem kroz studije i projekte, zatim na razvoju specijaliziranih računalnih aplikacija, implementaciji i razvoju GIS i ITS sustava, istraživanju sustava mobilnog pozicioniranja, satelitskih radio-navigacijskih (GNSS) i foto-video senzora za potrebe istraživanja u prometu i primjeni u prometnom inženjerstvu. Kao vanjski suradnik na Fakultetu prometnih znanosti sudjelovao je u održavanju nastave u kolegiju Osnove prometnog inženjerstva. Od 2010. godine zaposlen je kao domenski ekspert za područje inteligentnih transportnih sustava u kompaniji Ericsson Nikola Tesla. Zadužen je za projektiranje rješenja u domeni inteligentnih transportnih sustava, vodio je projekte financirane sredstvima EU-a u domeni transporta (trogodišnji projekt ePoziv). Na razini grupacije Ericsson, dio je globalnog ekspertnog tima za inteligentne transportne sustave. U suradnji s akademskim institucijama sudjeluje kao mentor u projektima Ljetnih kampova Ericsson Nikola Tesla. Kao gost predavač sudjelovao je na brojnim kolegijima na Fakultetu prometnih znanosti. Uže područje interesa su inteligentni transportni sustavi, održiva mobilnost i primjena suvremenih komunikacijskih tehnologija u prometu i transportu. Objavio je 36 znanstvenih radova u zbornicima s međunarodnih i domaćih skupova. Oženjen je i otac dva djeteta. Izvrsno se služi engleskim jezikom.

DODACI

Dodatak 1 – Anketni upitnik na hrvatskom jeziku

Anketni upitnik

za potrebe istraživanja u sklopu izrade doktorske disertacije „Model procjene urbane mobilnosti zasnovan na zapisima o aktivnostima korisnika u javnim pokretnim komunikacijskim mrežama“

Zahvaljujem vam na vremenu i sudjelovanju u istraživanju u sklopu izrade doktorske disertacije. Disertacija ima za cilj predložiti novi pristup procjene urbane mobilnosti stanovnika, temeljen na podacima o telekomunikacijskoj aktivnosti (glasovni poziv, tekstualna poruka, pristup internetu) korisnika u javnim pokretnim komunikacijskim mrežama. Pokazatelji urbane mobilnosti izvede se iz podataka o telekomunikacijskim aktivnostima i ujediniju se u indeks urbane mobilnosti stanovnika.

Urbana mobilnost predstavlja mogućnost kretanja pojedinca u urbanom prostoru na organiziran i suvisao način, sukladno njegovim fiziološkim, intelektualnim i društveno-ekonomskim potrebama, korištenjem postojeće prometne, komunalne i informacijsko-komunikacijske infrastrukture. Kako bi se identificirale slabosti i snage prometnog sustava, identificirali ključni ili kritični elementi i pružio uvid u stanje urbane mobilnosti, urbanu mobilnost je potrebno procijeniti. Procjena mobilnosti se obavlja temeljem vrijednosti pokazatelja urbane mobilnosti, pri čemu je pokazatelj urbane mobilnosti definiran kao veličina temeljena na podacima iz segmenta prometnog sustava koja opisuje pojave koje utječu na urbanu mobilnost.

Cilj ovog anketnog istraživanja jest definirati odnose između pokazatelja urbane mobilnosti i vrijednosti procjene mobilnosti, s ciljem definiranja metodologije za procjenu urbane mobilnosti. Anketni upitnik sadrži pitanja koja uključuju vrijednosti pokazatelja urbane mobilnosti, definirane na način da obuhvate karakteristične vrijednosti pokazatelja, iz unaprijed definiranih raspona, kao i predloženi postupak za procjenu mobilnosti, koji je temeljen na saznanjima iz znanstvene literature.

Molim vas da temeljem vlastite prosudbe svakom pitanju (scenariju mobilnosti) pridijelite odgovarajuću vrijednost korištenjem predloženog postupka za procjenu mobilnosti. Rezultati anketnog istraživanja će osigurati poveznicu između vrijednosti pokazatelja i vrijednosti procjene mobilnosti, te će se koristiti kao jedan od ulaznih podataka za proces procjene mobilnosti.

Kroz pitanja su ponuđene vrijednosti odgovarajućih pokazatelja, a zadatak ispitivača je na osnovi njih dati vlastitu procjenu mobilnosti, sukladno primjeru u nastavku:

Ako je <broj putovanja>, <pokazatelj trajanja putovanja> i <pokazatelj prijeđenog puta (udaljenosti)>, mobilnost je <ocjena mobilnosti>.

Primjer 1.

Ukoliko je (primjerice, tijekom noći) ukupni broj putovanja u urbanom okruženju mali, a moje je putovanje trajalo kratko, prilikom čega sam prešao srednju udaljenost, po mojoj procjeni mobilnost je _____.

Primjer 2.

Ukoliko je (primjerice, tijekom jutarnjeg vršnog opterećenja) ukupni broj putovanja u urbanom okruženju mali, a moje je putovanje trajalo dugo, prilikom čega sam prešao manju udaljenost, po mojoj procjeni mobilnost je _____.

Korišteni pokazatelji mobilnosti su:

1. Pokazatelj „broj putovanja“ odnosi se na broj putovanja između pojedinih urbanih područja u vremenskom okviru. Predstavlja zbroj zabilježenih kretanja svih korisnika između pojedinih urbanih područja u odgovarajućem vremenskom okviru.

Moguće vrijednosti:

- a. Mali broj putovanja (Broj putovanja koji je u urbanim uvjetima u karakterističnom danu prisutan u razdobljima kada se u pravilu ne odvijaju putovanja vezana za posao, zabavu, rekreaciju, trgovinu ili društvena zbivanja.).
- b. Srednji broj putovanja (Broj putovanja koji je u urbanim uvjetima karakterističan za razdoblje izvan vršnog prometnog opterećenja. Odnosi se na broj putovanja koji je karakterističan za razdoblja izvanvršnih opterećenja, primjerice; tijekom razdoblja kada su karakteristična putovanja motivirana trgovinom, rekreacijom ili društvenim aktivnostima.).
- c. Velik broj putovanja (Broj putovanja koji je u urbanim uvjetima karakterističan za razdoblja vršnog prometnog opterećenja, odnosno tijekom razdoblja kada tijekom karakterističnog dana stanovnici vršnog opterećenja putuju na ili s posla.).

2. Pokazatelj „trajanje putovanja“ odnosi se na vremensko trajanje svakog pojedinog putovanja.

Moguće vrijednosti pokazatelja:

- a. Kratko trajanje putovanja (do 33 % najdužeg putovanja)
- b. Srednje trajanje putovanja (od 34 % do 66 % najdužeg putovanja)
- c. Dugo trajanje putovanja (od 67 % do 100 % najdužeg putovanja)

3. Pokazatelj „udaljenost“ se odnosi na udaljenost koju je korisnik prevalio na putovanju između pojedinih urbanih područja, odnosno predstavlja udaljenost između izvora i odredišta putovanja.

Moguće vrijednosti pokazatelja:

- a. Mala udaljenost (do 33 % najdužeg putovanja)
- b. Srednja udaljenost (od 34 % do 66 % najdužeg putovanja)
- c. Velika udaljenost (od 67 % do 100 % najdužeg putovanja)

Broj putovanja je pokazatelj koji se odnosi na cjelokupan sustav, odnosno ispitanik procjenjuje mobilnost u kontekstu ukupnog broja dionika u prometnom sektoru u odgovarajućem vremenskom razdoblju. Ostali pokazatelji, pokazatelji trajanja putovanja i pokazatelji prijeđene udaljenosti, odnose se na individualno putovanje te ispitanik procjenjuje mobilnost promatrajući te vrijednosti iz perspektive krajnjeg korisnika.

Temeljem vrijednosti pokazatelja za svaki pojedini scenarij, molimo vas da svakom scenariju pridijelite vašu ocjenu mobilnosti, korištenjem predložene skale:

- ***Izrazito visoka mobilnosti*** - Kod „Izrazito visoke mobilnosti“ u prometnom sustavu vladaju uvjeti potpuno slobodnog prometnog toka, s punom slobodom manevriranja, gdje sudionici biraju brzinu kretanja, sloboda kretanja nije narušena, a vremena čekanja su minimalna. Korisnici su izrazito zadovoljni. **Na skali of 1 do 6 označava se kao 6.**
- ***Visoka mobilnost*** - Kod „Visoke mobilnosti“ u prometnom sustavu vladaju uvjeti slobodnog prometnog toka, sloboda manevriranja nije narušena, minimalno je ograničena brzina kretanja, sloboda kretanja je u maloj mjeri narušena, a vremena čekanja su rijetka i kratka. Korisnici su zadovoljni. **Na skali of 1 do 6 označava se kao 5.**
- ***Viša srednja mobilnost*** - Kod „Više srednje mobilnosti“ u prometnom sustavu vladaju uvjeti stabilnog prometnog toka, sloboda manevriranja je ograničena, ograničena je brzina kretanja, ograničena je sloboda kretanja i vremena čekanja su osjetna. Korisnici su uglavnom zadovoljni. **Na skali of 1 do 6 označava se kao 4.**
- ***Niža srednja mobilnost*** - Kod „Niže srednje mobilnosti“ u prometnom sustavu vladaju uvjeti nestabilnog prometnog toka, s malom mogućnosti manevriranja, s bitno ograničenim brzinama, jasno narušenom slobodom kretanja i većim prosječnim

vremenima čekanja. Korisnici su uglavnom nezadovoljni. **Na skali of 1 do 6 označava se kao 3.**

- **Niska mobilnosti** - Kod „Niske mobilnosti“ u prometnom sustavu vladaju uvjeti nestabilnog prometnog toka s kretanjem u nizu, sloboda manevriranja je gotovo stalno narušena, brzina kretanja je značajno ograničena i javljaju se zastoji, sloboda kretanja je gotovo stalno narušena, vremena čekanja su velika. **Na skali of 1 do 6 označava se kao 2.**
- **Izrazito niska mobilnost** - Kod „Izrazito niske mobilnosti“ u prometnom sustav vladaju uvjeti usiljeno-prisilnog prometnog toka, sloboda manevriranje je onemogućena u potpunosti, brzina kretanja je manja od kritičnih brzina, sloboda kretanja je onemogućena u potpunosti, vremena čekanja su izrazito velika. **Na skali of 1 do 6 označava se kao 1.**

Premda je identitet eksperata poznat autoru, odgovori će biti tretirani kao anonimni, te pojedini stavovi i mišljenje eksperata neće biti javno iznošeni. Zahvaljujem na suradnji.

Rb.	Broj putovanja	Trajanje putovanja	Udaljenost	Procjena mobilnosti
1	Mali broj putovanja	Kratko trajanje putovanja	Mala udaljenost	
2	Mali broj putovanja	Kratko trajanje putovanja	Srednja udaljenost	Izrazito visoka mobilnosti
3	Mali broj putovanja	Kratko trajanje putovanja	Velika udaljenosti	Visoka mobilnost
4	Mali broj putovanja	Srednje trajanje putovanja	Mala udaljenost	Viša srednja mobilnost
5	Mali broj putovanja	Srednje trajanje putovanja	Srednja udaljenost	Niža srednja mobilnost
6	Mali broj putovanja	Srednje trajanje putovanja	Velika udaljenosti	Niska mobilnost
7	Mali broj putovanja	Dugo trajanje putovanja	Mala udaljenost	Izrazito niska mobilnost
8	Mali broj putovanja	Dugo trajanje putovanja	Srednja udaljenost	
9	Mali broj putovanja	Dugo trajanje putovanja	Velika udaljenosti	
10	Srednji broj putovanja	Kratko trajanje putovanja	Mala udaljenost	
11	Srednji broj putovanja	Kratko trajanje putovanja	Srednja udaljenost	
12	Srednji broj putovanja	Kratko trajanje putovanja	Velika udaljenosti	
13	Srednji broj putovanja	Srednje trajanje putovanja	Mala udaljenost	
14	Srednji broj putovanja	Srednje trajanje putovanja	Srednja udaljenost	
15	Srednji broj putovanja	Srednje trajanje putovanja	Velika udaljenosti	
16	Srednji broj putovanja	Dugo trajanje putovanja	Mala udaljenost	

Slika: Primjer ispunjavanja anketnog upitnika

Anketni upitnik

Ukoliko upitnik ispunjavate na računalu, molim izaberite vrijednost s padajuće liste (u excel datoteci), a ukoliko je upitnik dostavljen u papirnatom obliku, molim upišite numeričke vrijednosti u intervalu od 1 do 6, pri čemu „1“ označava *izrazito nisku mobilnost*, a „6“ *izrazito visoku mobilnost, sukladno uputama na stranicama 1- 3.*

Rb.	Broj putovanja	Trajanje putovanja	Udaljenost	Procjena mobilnosti
1	Mali broj putovanja	Kratko trajanje putovanja	Mala udaljenost	
2	Mali broj putovanja	Kratko trajanje putovanja	Srednja udaljenost	
3	Mali broj putovanja	Kratko trajanje putovanja	Velika udaljenosti	
4	Mali broj putovanja	Srednje trajanje putovanja	Mala udaljenost	
5	Mali broj putovanja	Srednje trajanje putovanja	Srednja udaljenost	
6	Mali broj putovanja	Srednje trajanje putovanja	Velika udaljenosti	
7	Mali broj putovanja	Dugo trajanje putovanja	Mala udaljenost	
8	Mali broj putovanja	Dugo trajanje putovanja	Srednja udaljenost	
9	Mali broj putovanja	Dugo trajanje putovanja	Velika udaljenosti	
10	Srednji broj putovanja	Kratko trajanje putovanja	Mala udaljenost	
11	Srednji broj putovanja	Kratko trajanje putovanja	Srednja udaljenost	
12	Srednji broj putovanja	Kratko trajanje putovanja	Velika udaljenosti	
13	Srednji broj putovanja	Srednje trajanje putovanja	Mala udaljenost	
14	Srednji broj putovanja	Srednje trajanje putovanja	Srednja udaljenost	
15	Srednji broj putovanja	Srednje trajanje putovanja	Velika udaljenosti	
16	Srednji broj putovanja	Dugo trajanje putovanja	Mala udaljenost	
17	Srednji broj putovanja	Dugo trajanje putovanja	Srednja udaljenost	
18	Srednji broj putovanja	Dugo trajanje putovanja	Velika udaljenosti	
19	Velik broj putovanja	Kratko trajanje putovanja	Mala udaljenost	
20	Velik broj putovanja	Kratko trajanje putovanja	Srednja udaljenost	
21	Velik broj putovanja	Kratko trajanje putovanja	Velika udaljenosti	
22	Velik broj putovanja	Srednje trajanje putovanja	Mala udaljenost	
23	Velik broj putovanja	Srednje trajanje putovanja	Srednja udaljenost	
24	Velik broj putovanja	Srednje trajanje putovanja	Velika udaljenosti	
25	Velik broj putovanja	Dugo trajanje putovanja	Mala udaljenost	
26	Velik broj putovanja	Dugo trajanje putovanja	Srednja udaljenost	
27	Velik broj putovanja	Dugo trajanje putovanja	Velika udaljenosti	

Questionnaire

for the purposes of research as part of the doctoral thesis "Model for estimating urban mobility based on the records of user activities in public mobile networks "

Thank you for your time and participation in this questionnaire conducted as a part of a doctoral thesis research. The dissertation aims to propose a new approach to estimate the urban mobility based on data on telecommunications activities (voice calls, text messaging, Internet access) of users in public mobile telecommunications networks. Indicators of urban mobility are derived from data on telecommunications activities and will be integrated in the index of urban mobility.

Urban mobility can be defined as a possibility of movement of individuals in urban environment in an organized and coherent manner in accordance with their physiological, intellectual and socio-economic needs, using of existing transport, utility and ICT infrastructure. In order to identify weaknesses and strengths of the transport system, to identify key or critical elements and provide insight into the urban mobility, urban mobility has to be assessed. Mobility assessment is performed based on the value of urban mobility indicator, wherein the urban mobility indicator is defined as value based on the data from the mobility system, that is describing phenomena that affect urban mobility.

The aim of this survey is to define the relationship between indicators of urban mobility and value of mobility assessment, with the aim of defining a methodology for assessing urban mobility. The questionnaire contains questions which include urban mobility indicator values, defined by the pre-defined range, and the proposed method for estimation of urban mobility, which is based on the findings from the scientific literature.

The experts should, based on their own judgment, for every question assign the appropriate value using the proposed procedure for the mobility assessment. Survey results will provide a connection between the value of urban mobility indicators and assessment value of mobility index, and will be used as one of the input data for the urban mobility assessment process.

Questions contains the characteristic values of indicators, and the task of the examiner is give their own assessment of urban mobility, like in the examples below:

If the value of is <indicator number of trips>, <indicator of travel time> and <distance travelled indicator (distance)>, mobility is <mobility index value>.

Example 1.

If (for example, at night) the total number of trips in the urban environment small, and my journey was short, during which I crossed the medium distance, in my opinion mobility is _____.

Example 2.

If (for example, during the morning peak hour), the total number of trips in the urban environment is small, and my journey took a long time, during which I crossed small distance, in my opinion mobility is _____.

The used indicators of mobility are:

1. The indicator "number of trips" refers to the number of trips between certain urban areas in the time frame. Represents the sum of the recorded movement of users between certain urban areas within an appropriate timeframe.

Possible values:

- a. A small number of trips (Number of trips in urban environment during some typical hours in day were trips related to business, entertainment, recreation, trade or social motivated trips usual do not occur.
- b. A medium number of trips (Number of trips in urban environment for the period outside of peak traffic load. Refers to the number of trips that is characteristic for the period of off-peak demand, for example, during the period when the typical trips motivated by trade, recreation or social activities) are performed.
- c. A large number of trips (Number of trips in urban environment characteristic for the period of peak traffic hours or during periods of time during a typical day when residents are traveling to or from work.)

2. The indicator "travel time" refers to the duration of each journey.

Possible values of indicators:

- a. The short duration of travel (up to 33% of the longest journey)
- b. The medium duration of travel (34-66% of the longest journey)
- c. The long duration of travel (from 67% to 100% of the longest journey)

3. Indicator "distance" refers to the distance travelled by the users traveling between different urban areas, and stands for the distance between the source and destination of travel.

Possible values of indicators:

- a. Short distance (up to 33% of the longest journey)
- b. Medium distance (34 to 66% of the longest journey)
- c. Great distance (from 67% to 100% of the longest journey)

The number of trips is an indication that refers to the entire system, and examiner is asked to rate mobility in the context of the total number of participants in the transport sector in the appropriate time period. Other indicators, like travel time and distance relate to individual travel and respondent that estimates mobility shall observe this values from the perspective of the end user.

Based on the value of the indicator for each scenario, please assign your assessment of mobility for each question, using the proposed scale:

- Very high mobility - The "**Very high mobility**" represents the conditions in transport system with totally free traffic flow, with full freedom of manoeuvre, where participants choose the speed of movement, freedom of movement is not impaired, and waiting times are minimal. The users are extremely satisfied. On a scale of 1 to 6 it is represented by **mark 6**.
- High mobility - The "**High Mobility**" in the transport system represents the conditions of free traffic flow, freedom of manoeuvre is not violated, the minimum restrictions of speed are present, freedom of movement is to a small extent undermined, and waiting times are rare and short. Users are satisfied. On a scale of 1 to 6 it is represented by **mark 5**.

- Medium-high mobility - The "**Medium high-mobility**" in the transport system represents the conditions of stable traffic flow, freedom of manoeuvre is limited, speed is limited, freedom of movement is limited and waiting times are noticeable. The users are generally satisfied. On a scale of 1 to 6 it is represented by **mark 4**.
- Medium low mobility - The "**Medium low mobility**" in the transport system represents conditions of unstable traffic flow, with little manoeuvrability, with significantly limited speeds, clearly impaired freedom of movement and higher average waiting times. The users are generally dissatisfied. On a scale of 1 to 6 it is represented by **mark 3**.
- Low mobility - The "**Low mobility**" in the transport system represents conditions of unstable traffic flow to the movement in a line, freedom of manoeuvre is almost constantly violated, speed is significantly limited and there are delays, freedom of movement is almost constantly disturbed, waiting times are high. On a scale of 1 to 6 it is represented by **mark 2**.
- Very low mobility - The "**Very low mobility**" in the transport system represents conditions of a forced traffic flow, freedom of manoeuvre is completely disabled, average speed is less than the critical speed, freedom of movement is disabled completely, waiting times are extremely high. On a scale from 1 to 6 it is represented by **mark 1**.

Although the identity of experts is known to author, answers will be treated as anonymous, and individual attitudes and opinions of experts will not be publicly cited. Thanks you for your assistance and cooperation.

No.	Number of trips	Travel time	Distance	Mobility assessment
1	Small number of trips	Short duration of travel	Short distance	
2	Small number of trips	Short duration of travel	Medium distance	
3	Small number of trips	Short duration of travel	Great distance	
4	Small number of trips	Mean duration of travel	Short distance	
5	Small number of trips	Mean duration of travel	Medium distance	
6	Small number of trips	Mean duration of travel	Great distance	
7	Small number of trips	The long duration of travel	Short distance	
8	Small number of trips	The long duration of travel	Medium distance	
9	Small number of trips	The long duration of travel	Great distance	
10	Medium number of trips	Short duration of travel	Short distance	
11	Medium number of trips	Short duration of travel	Medium distance	
12	Medium number of trips	Short duration of travel	Great distance	
13	Medium number of trips	Mean duration of travel	Short distance	
14	Medium number of trips	Mean duration of travel	Medium distance	
15	Medium number of trips	Mean duration of travel	Great distance	
16	Medium number of trips	The long duration of travel	Short distance	
17	Medium number of trips	The long duration of travel	Medium distance	

Figure: Example of a filled questionnaire

Questionnaire

Please select a value from the drop-down list, that by your opinion represents the assessment of mobility value based on value of combination of certain indicators.

No.	Number of trips	Travel time	Distance	Mobility assessment
1	Small number of trips	Short duration of travel	Short distance	
2	Small number of trips	Short duration of travel	Medium distance	
3	Small number of trips	Short duration of travel	Great distance	
4	Small number of trips	Mean duration of travel	Short distance	
5	Small number of trips	Mean duration of travel	Medium distance	
6	Small number of trips	Mean duration of travel	Great distance	
7	Small number of trips	The long duration of travel	Short distance	
8	Small number of trips	The long duration of travel	Medium distance	
9	Small number of trips	The long duration of travel	Great distance	
10	Medium number of trips	Short duration of travel	Short distance	
11	Medium number of trips	Short duration of travel	Medium distance	
12	Medium number of trips	Short duration of travel	Great distance	
13	Medium number of trips	Mean duration of travel	Short distance	
14	Medium number of trips	Mean duration of travel	Medium distance	
15	Medium number of trips	Mean duration of travel	Great distance	
16	Medium number of trips	The long duration of travel	Short distance	
17	Medium number of trips	The long duration of travel	Medium distance	
18	Medium number of trips	The long duration of travel	Great distance	
19	Large number of trips	Short duration of travel	Short distance	
20	Large number of trips	Short duration of travel	Medium distance	
21	Large number of trips	Short duration of travel	Great distance	
22	Large number of trips	Mean duration of travel	Short distance	
23	Large number of trips	Mean duration of travel	Medium distance	
24	Large number of trips	Mean duration of travel	Great distance	
25	Large number of trips	The long duration of travel	Short distance	
26	Large number of trips	The long duration of travel	Medium distance	
27	Large number of trips	The long duration of travel	Great distance	